



Universidade Federal Rural de Pernambuco
Departamento de Estatística e Informática
Programa de Pós-Graduação em Informática Aplicada

Autômatos Celulares para Otimização de Cenários em Gerenciamento de Recursos de Energia

Lucas Sampaio Leite

Recife

Junho de 2016

Lucas Sampaio Leite

Autômatos Celulares para Otimização de Cenários em Gerenciamento de Recursos de Energia

Orientador: Prof. Dr. Jones Oliveira de Albuquerque

Coorientador: Prof. Dr. Hernande Pereira da Silva

Dissertação de mestrado apresentada ao Curso de Pós-Graduação em Informática Aplicada da Universidade Federal Rural de Pernambuco, como requisito parcial para obtenção do grau de Mestre em Informática Aplicada.

Recife

Junho de 2016

Universidade Federal Rural de Pernambuco
Departamento de Estatística e Informática
Programa de Pós-Graduação em Informática Aplicada

Autômatos Celulares para Otimização de Cenários em Gerenciamento de Recursos de Energia

Lucas Sampaio Leite

Dissertação julgada adequada para obtenção do título de Mestre em Informática Aplicada, defendida e aprovada por unanimidade em 10/06/2016 pela Comissão Examinadora.

Orientador:

Prof. Dr. Jones Oliveira de Albuquerque
Universidade Federal Rural de Pernambuco – UFRPE

Coorientador:

Prof. Dr. Hernande Pereira da Silva
Universidade Federal Rural de Pernambuco – UFRPE

Banca Examinadora:

Prof. Dr. Sérgio Castelo Branco Soares
Universidade Federal de Pernambuco – UFPE

Prof. Dr. Cláudio Tadeu Cristino
Universidade Federal Rural de Pernambuco – UFRPE

Prof. Dra. Silvana Bocanegra
Universidade Federal Rural de Pernambuco – UFRPE

“That is the paradox of the epidemic: that in order to create one contagious movement, you often have to create many small movements first.”

– Malcolm Gladwell, *The Tipping Point*.

Aos meus pais,
Joaquim e Auzeni.

Agradecimentos

A Deus, pelo dom da vida, pela saúde e força de vontade concedida na busca do conhecimento.

À Universidade Federal Rural de Pernambuco, ao Programa de Pós-graduação em Informática Aplicada e a seu corpo docente. Pela estrutura e por terem me proporcionado uma formação de qualidade.

À FACEPE pelo apoio financeiro a este trabalho. Aos financiadores do Desert-MAP, ao qual cito no decorrer da dissertação.

Ao ONS e ao grupo Neoenergia pelo fornecimento dos dados.

Aos meus pais, pela educação e exemplo ao longo da vida. Aos meus irmãos e a Maíra de Vasconcelos.

Ao meu orientador Jones Albuquerque por suas orientações, motivações, paciência e incentivo.

Ao meu coorientador Hernande Pereira e a Ary D'ajuz pela paciência e disponibilidade.

Aos demais que não estão aqui citados, mas que contribuíram para realização deste trabalho.

Resumo

O objetivo principal desta dissertação é apresentar uma proposta baseada em autômatos celulares, para auxiliar no gerenciamento de matrizes energéticas. Para isso foi utilizado um modelo de captura de dados geoespaciais por satélite que foi chamado de Desert-MAP, um modelo de otimização baseado em programação linear inteira mista e modelos compartimentais para caracterização de demanda. Os resultados trazem cenários preditivos de crescimento de demanda para as cidades atendidas pelo Grupo Neoenergia em uma perspectiva de dez anos. Também é proposto um modelo para operação do despacho ótimo de usinas térmicas para o Sistema Interligado Nacional. E através de técnicas de Geoprocessamento e Sensoriamento Remoto é possível prever possíveis localizações para expansão da matriz energética no estado de Pernambuco.

Palavras-chave: Autômatos Celulares, Modelos Compartimentais, Otimização, PLIM, Geoprocessamento, Sensoriamento Remoto.

Abstract

The main objective of this Master thesis is to present a proposal based on cellular automata, to help manage energy matrixes. For this we used a model of geospatial data capture by satellite that was called Desert-MAP, an optimization model based on mixed integer linear programming and compartmental modeling for demand to characterization. The results provide predictive scenarios of demand growth for cities served by Neoenergia Group in a perspective of ten years. It is also proposed a model for optimal dispatch operation of thermal power plants to the National Interconnected System. And through GIS and remote sensing techniques it is possible to predict possible locations for the expansion of the energy matrix in the state of Pernambuco.

Keywords: Cellular Automata, Compartmental models, optimization, MILP, GIS, Remote Sensing.

Sumário

1	Introdução	1
1.1	Motivação	1
1.2	Objetivos	3
1.3	Contribuições obtidas	4
1.4	Organização do trabalho	4
2	Fundamentação Teórica	5
2.1	Modelagem Matemática de Otimização	6
2.1.1	Programação Linear Inteira Mista	8
2.1.2	Problema de Localização de Facilidades	9
2.2	Geoprocessamento e Sensoriamento Remoto	10
2.2.1	Desertificação	11
2.3	Epidemiologia Matemática e Computacional	14
2.3.1	Modelos Epidemiológicos Compartimentais	15
2.4	Autômatos Celulares	20
2.4.1	Definição	21
2.4.2	Dimensões e formatos	23

2.4.3	Limites e condições de fronteira	24
2.4.4	Vizinhança e regras de transição	24
2.4.5	Discretização de Modelos Epidemiológicos utilizando Autômatos celulares	25
3	Configuração do Modelo	27
3.1	Modelagem de Otimização para despacho de usinas térmicas em sistemas hidrotérmicos	28
3.1.1	Contextualização e descrição do problema	28
3.1.2	Modelagem Matemática	30
3.2	Geração de Mapas de Susceptibilidade de Solos por Geoprocessamento e Sensoriamento Remoto	35
3.2.1	Aquisição de imagens	37
3.2.2	Pré-processamento	38
3.2.3	Processamento e extração de informações	40
3.3	<i>Energy Epidemiology</i> através da interpretação de Modelos Compartimentais	41
3.3.1	Modelo SIRS para crescimento de demandas	42
3.3.2	Modelo SIS para distribuição energética	45
3.4	Simulador baseado em Autômatos Celulares	46
3.4.1	Dimensões de leitura de informações	47
3.4.2	Dimensões baseadas em modelos epidemiológicos compartimentais . .	47
3.4.3	Algoritmo geral do simulador	49
4	Resultados	51

4.1	Dimensão de otimização do despacho de usinas térmicas para o Sistema Interligado Nacional	51
4.1.1	Levantamento de dados para o modelo de otimização	53
4.1.2	Resultados da Simulação	55
4.2	Dimensão de coleta de dados ambientais através de Geoprocessamento e Sensoriamento Remoto	60
4.3	Dimensões baseadas em Modelos Matemáticos Epidemiológicos Compartmentais	64
4.3.1	Dimensão de previsão de crescimento de demanda	65
4.3.2	Dimensão de distribuição de energia	69
5	Conclusões e Trabalhos Futuros	72
5.1	Trabalhos Futuros	73
A	Dicionário de dados e resultados desta dissertação.	85
A.1	Desert-MAP	85
A.2	Modelagem de Otimização	85
A.2.1	SETs	85
A.2.2	Arquivos base do modelo NEWAVE	86
A.2.3	Demanda ONS	86
A.2.4	Boletim diário ONS	86
A.3	Modelagem Epidemiológica	86
A.3.1	Planilhas de demanda do Grupo Neoenergia	86
A.3.2	Distribuição celular	87

Lista de Tabelas

2.1	Características espectrais dos instrumentos OLI e TIRS / LANDSAT8.	12
2.2	Catálogo de combinações de bandas LANDSAT 8. Fonte: ESRI.	13
3.1	Imagens do Satélite LANDSAT utilizadas na Pesquisa.	39
4.1	Preenchimento dos parâmetros a partir dos dados coletados.	56

Lista de Figuras

1.1	Visão geral da estrutura de modelagem construída na dissertação.	3
2.1	Etapas do processo de modelagem. Adaptado de: [40].	7
2.2	Ilustração do conceito de espectroscopia. Fonte: [101].	11
2.3	Áreas brasileiras susceptíveis ao processo de desertificação. Fonte: [14]. . . .	14
2.4	Simulação baseada nas regras do Jogo da Vida. Fonte: [67].	21
2.5	Representação de uma célula e sua vizinhança. Fonte: [2].	22
2.6	Representação de um Autômato Celular: a) unidimensional, b) bidimensional e c) tridimensional. Fonte: [63].	23
2.7	Tipos de formatos das células de um Autômato Celular: a) quadrado, b) hexagonal-Z, c) hexagonal-A e d) triangular. Fonte: adaptado de [120]. . . .	23
2.8	Representação das vizinhanças de a) Von Neumann de raio 1, b) Moore de raio 1, c) Von Neumann de raio 2 e d) Moore de raio 2.	25
3.1	Representação de um sistema hidrotérmico genérico.	29
3.2	Representação do SIN. Adaptado de: [69]	30
3.3	Fluxograma da metodologia para geração de mapas de susceptibilidade de solos ao processo de desertificação.	37
3.4	Fluxograma do modelo compartimental SIRS.	43
3.5	Fluxograma do modelo compartimental SIS.	45

3.6	Modelagem do autômato celular para o gerenciamento de recursos de energia. Adaptado de: [2].	49
4.1	Resumo da resolução e simulação da operação do SIN (10/11/2015) pela plataforma AIMMS.	52
4.2	(a) Variação da demanda horária Demanda horária dos subsistemas do SIN e (b) Resultado da simulação da variação de carga térmica adicional gerada pelos subsistemas do SINor fonte de geração para o dia 10/11/2015.	57
4.3	Resultado do montante da geração térmica (inflexível + adicional) para a operação do dia 10/11/2015.	58
4.4	Resultado da simulação do SIN por fonte de geração para o dia 10/11/2015.	59
4.5	(a) Resultados dos intercâmbios fornecidos entre os subsistemas para operação do dia 10/11/2015. (b)Resultados dos intercâmbios recebidos entre os subsistemas para operação do dia 10/11/2015.	61
4.6	Mapa de níveis de susceptibilidade do solo ao processo de desertificação de Pernambuco para o ano de 2015.	63
4.7	Níveis de degradação do solo no Município de Floresta (PE) em (a) 1976-2008 (b) 2004 e (c) 2015.	64
4.8	Representação do núcleo de desertificação de Cabrobó através do (a) mapa de risco e (b) dimensão de entrada para o simulador.	65
4.9	Evolução da dimensão de previsão de crescimento de demanda. Em (a) o estado inicial para o ano de 2013. A evolução em (b) 2014, (c) 2015, (d) 2016, (e) 2017, (f) 2018, (g) 2021 e (h) 2026. Em azul marinho, as cidades pertencentes ao compartimento de susceptíveis. Em azul claro, as cidades que apresentam crescimento de demanda (infectadas) e em verde as cidades com crescimento estabilizado (recuperados). As células vermelhas não possuem representatividade.	67
4.10	Cenários gerados pela dimensão de previsão de crescimento de demanda para os anos de 2014-2026.	68

4.11	Demanda média anual de carga distribuída pelo grupo Neoenergia nos período entre 2013 e 2015.	69
4.12	Variação dos indivíduos Susceptíveis e Infectados durante a simulação do modelo SIS de distribuição de energia.	70
4.13	Simulação da visualização do processo de distribuição de energia por um autômato celular.	71

Capítulo 1

Introdução

1.1 Motivação

Uma nova abordagem denominada *Energy Epidemiology* é proposta pelo Instituto de Energia do Reino Unido (*Energy Institute UCL*) [50]. Esta abordagem procura criar um quadro multidisciplinar relevante e atraente para a realização de pesquisas na demanda final da energia. Seu principal objetivo é investigar as causas e efeitos dos fatores chave da demanda de energia dentro de uma população, que pode ser definida em várias escalas de indivíduos e edifícios até comunidades e bairros.

Tradicionalmente os modelos matemáticos epidemiológicos baseados em equações diferenciais têm sido utilizados na modelagem e prevenção de doenças [59, 9, 22]. O interesse de estudar o espalhamento de doenças é explicar como a doença se propaga por meio das interações entre os indivíduos e não pela doença em cada indivíduo. A adoção desses modelos na modelagem de outros sistemas vêm sendo adotada, como na difusão de mídias sociais [117, 35] e também recentemente como componente da difusão da energias renováveis [68].

A simulação de cenários incluindo modelos epidemiológicos têm sido realizada por Autômatos Celulares que representam sistemas dinâmicos, para os quais o tempo e espaço são discretos. A vantagem dessa modelagem conjunta entre os modelos epidemiológicos e autômatos celulares é descrever epidemias de forma a considerar os processos individuais de contatos e os aspectos espaciais dos indivíduos, quando estes aspectos não são permitidos apenas com a modelagem epidemiológica baseada em equações diferenciais [110], as quais capturam

e modelam apenas os comportamentos temporais e considera os indivíduos distribuídos de forma homogênea.

A pesquisa também aborda os processos de geração e transmissão de energia, através do planejamento da operação diária do despacho de usinas térmicas. É utilizada a modelagem de otimização, através da Programação Linear Inteira Mista (PLIM). Pretende-se que esta modelagem possa ser utilizada de forma complementar aos modelos já existentes, permitindo maior robustez aos processos de planejamento da operação. Também foi objeto motivador da pesquisa o *Plano Desert Renewable Energy Conservation (DRECP)*¹, que é um importante componente dos esforços de planejamento de energias renováveis da Califórnia. Seu objetivo é ajudar a fornecer uma proteção eficaz de conservação dos ecossistemas do deserto, permitindo simultaneamente o desenvolvimento adequado de projetos de energia renovável.

Nesta dissertação propõe-se utilizar a abordagem de *Energy Epidemiology* para modelar o crescimento de demandas de carga. A geração de mapas de susceptibilidade ao processo de desertificação foi utilizada como proposta para identificar possíveis áreas de risco e fornecer dados em tempo real para a gestão do planejamento de expansão das matrizes energéticas. Também foi proposto uma visão do processo de distribuição de energia através de modelos matemáticos epidemiológicos, obtendo heterogeneidade através da estrutura de Autômato Celular. E ainda, um modelo matemático de otimização para operação diária de um sistema hidrotérmico.

Uma visão geral da estrutura adotada como metodologia para construção deste trabalho pode ser visualizada na Figura 1.1. É proposto, através de técnicas de Geoprocessamento e Sensoriamento Remoto, a construção de uma metodologia para geração de mapas escaláveis e autonavegáveis, uma Modelagem Matemática de Otimização e a utilização do conceito de *Energy Epidemiology* para estudo de padrões e previsão de crescimento de demandas. Todas essas dimensões são unidas na proposta de um simulador baseado em autômatos celulares que auxilie nos planejamento e processos de geração, transmissão e distribuição de Energia Elétrica.

¹ <http://www.drecp.org/>

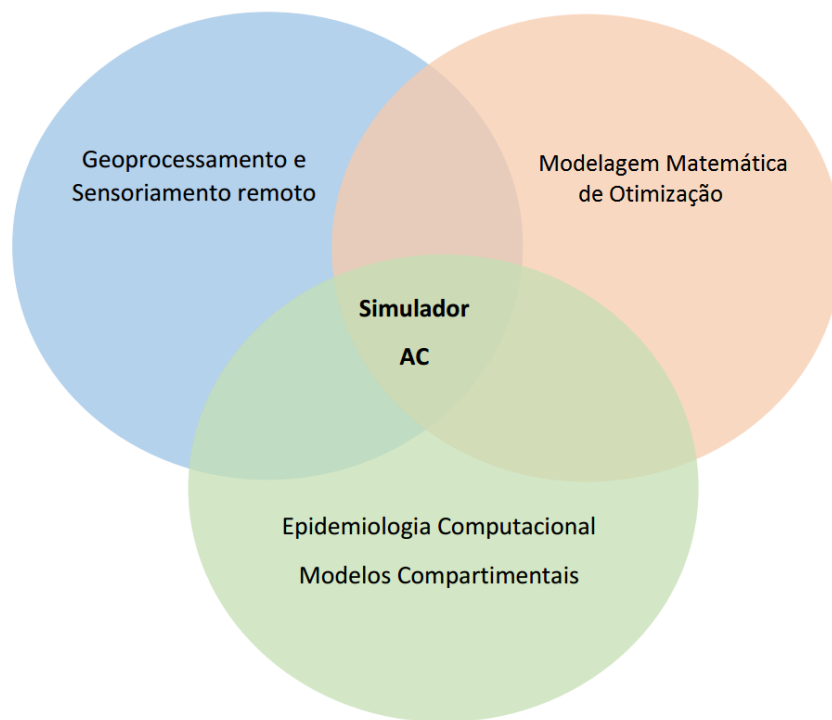


Figura 1.1: Visão geral da estrutura de modelagem construída na dissertação.

1.2 Objetivos

Nessa dissertação tem-se como objetivo apresentar uma proposta de modelagem utilizando Autômatos Celulares para otimização de cenários de gerenciamento de recursos de energia.

Para atingir o objetivo principal, alguns objetivos específicos são elencados:

- (i) Desenvolver uma metodologia para construção de mapas autonavegáveis, utilizando técnicas de geoprocessamento e sensoriamento remoto para que se possa fornecer índices de parâmetros ambientais e que visem auxiliar nas tomadas de decisões de projetos de implantação de fontes geradoras e linhas transmissoras de energia.
- (ii) Realizar simulações sobre criação de modelos matemáticos de otimização que expressem cenários de despacho da geração e a transmissão de recursos a um custo ótimo de operação.
- (iii) Interpretar modelos matemáticos utilizados em epidemiologia e aplicá-los sobre uma abordagem destinada a uma melhor visualização do processo de distribuição de energia e da compreensão de tendências e padrões de crescimento de demanda.

- (iv) Propor a modelagem de um simulador computacional, baseado em Autômatos Celulares, que integre as construções realizadas na satisfação dos objetivos (ii) e (iii).

1.3 Contribuições obtidas

É esperado que a realização da pesquisa e a construção desta dissertação contribuam na:

- (i) Construção de uma metodologia para geração automática de mapas autonavegáveis de leitura em tempo real para obtenção de parâmetros ambientais e que venha a auxiliar no planejamento da expansão e da transmissão de energia elétrica.
- (ii) Modelagem matemática de otimização para despacho de usinas térmicas em sistemas hidrotérmicos para auxiliar na operação diária do Sistema Interligado Nacional.
- (iii) Utilização do conceito de *Energy Epidemiology* para realização de previsões de demanda de energia utilizando modelos epidemiológicos compartimentais.
- (iv) A utilização da estrutura de um autômato celular juntamente com modelos epidemiológicos para visualização do processo de distribuição de energia.
- (v) Proposta de um modelo baseado em Autômatos Celulares, que auxilie no gerenciamento de recursos de energia, abrangendo as fases de geração, transmissão e distribuição e que também auxilie na proposta de expansão da energética.

1.4 Organização do trabalho

Essa dissertação é composta por cinco capítulos, incluindo esta introdução com a motivação e justificativa sobre o tema, os objetivos e contribuições obtidas. O Capítulo 2 abordará a fundamentação teórica necessária para compreensão do trabalho. O Capítulo 3 apresenta a metodologia utilizada na realização do trabalho. Neste capítulo ainda é proposto o simulador computacional baseado em autômatos celulares fazendo uso e exercendo o controle sobre cada uma das dimensões construídas. Os resultados dos experimentos realizados sobre a metodologia são apresentados e discutidos no Capítulo 4. As conclusões e sugestões de trabalhos futuros são apresentados no Capítulo 5.

Capítulo 2

Fundamentação Teórica

Neste capítulo é apresentada a base teórica necessária para compreensão da pesquisa. Assim, na Seção 2.1 é dada uma visão geral do processo de modelagem de um problema de otimização. A classe de problemas de Programação Linear Inteira Mista (PLIM) e a conceituação de problema multiperíodo de localização de facilidades são destacados por serem utilizados neste trabalho para uma proposta de modelagem do despacho ótimo de usinas térmicas em um sistema hidrotérmico.

A combinação de técnicas de Geoprocessamento e Sensoriamento remoto para auxiliar no estudo e combate a problemas ambientais é discutida na Seção 2.2. Esse conhecimento é necessário para facilitar a compreensão da metodologia construída neste trabalho para geração de mapas de susceptibilidade de solos ao processo de desertificação. Desertificação foi o problema ambiental escolhido para aplicação da metodologia neste trabalho. Neste sentido, a Subseção 2.2.1 apresenta uma base teórica sobre o tema. Nesta seção também são dados exemplos de composições de bandas espectrais de um dos satélites utilizados na pesquisa, o Landsat 8.

Tópicos em modelagem matemática epidemiológica são discutidos na Seção 2.3. O objetivo é fornecer entendimento dessa modelagem e apresentar alguns dos modelos matemáticos já consolidados e aplicados na epidemiologia: SIR, SIRS e o modelo SIS. Estes modelos baseados em compartimentos, são apresentados na forma de sistema de equações diferenciais e foram utilizados como base em algumas dimensões do simulador que será proposto. Portanto, esta teoria é importante para compreensão da utilização de modelos epidemiológicos compartimentais para resolução de problemas em gerenciamento de energia, tais como a previsão

de crescimento de demanda e o processo de distribuição energética.

Na Seção 2.4 é definido um Autômato Celular, estrutura matemática e computacional central da pesquisa. São elencados os principais elementos que o compõem (célula, estado, vizinhança, transição e tempo), e discutidas suas principais características. Na última subseção é mostrada a importância da utilização de Autômatos Celulares combinados a modelos epidemiológicos compartimentais. A proposta do simulador que será apresentada nessa dissertação procura obter a heterogeneidade da demanda por meio de dimensões espaço temporais. A espacialidade é obtida através da estrutura do Autômato Celular (AC) e a temporalidade está presente tanto nas características do AC, como também nos modelos epidemiológicos.

2.1 Modelagem Matemática de Otimização

Diversas aplicações na ciência e engenharia utilizam modelos matemáticos para expressar problemas de otimização. Essas aplicações envolvem o estudo de critérios de otimização, a determinação de métodos e algoritmos de solução, o estudo da estrutura de tais métodos e a realização de experimentos computacionais com métodos tanto sob condições de experimentação como sobre problemas da vida real [38].

Segundo [39], um modelo matemático é composto de um conjunto de relações matemáticas que representam uma abstração do sistema de mundo real em consideração. O modelo deve ser rico o suficiente para fornecer informações qualitativas úteis, bem como respostas numéricas que não induzam ao erro. No entanto, não deve possuir variáveis e restrições desnecessárias ou ele irá se tornar intratável para as entradas da análise ou a demanda de dados não poderá ser fornecida. [41, 91].

Problemas de otimização mantêm sempre o foco na maximização ou a minimização de alguma função sobre algum conjunto. Matematicamente isto pode ser escrito como:

$$(\text{min ou max}) z = f(x), \quad \forall x \in X,$$

sujeito a:

$$g_i(x) < 0, \quad \forall i = 1, \dots, k,$$

$$h_i(x) = 0, \quad \forall i = 1, \dots, l,$$

onde f é a função objetivo definida sobre um domínio X de soluções viáveis. $g_i(x)$ e $h_i(x)$ são as restrições de desigualdade e igualdade, respectivamente.

A modelagem de um problema de otimização é um processo iterativo, conforme ilustra a Figura 2.1.

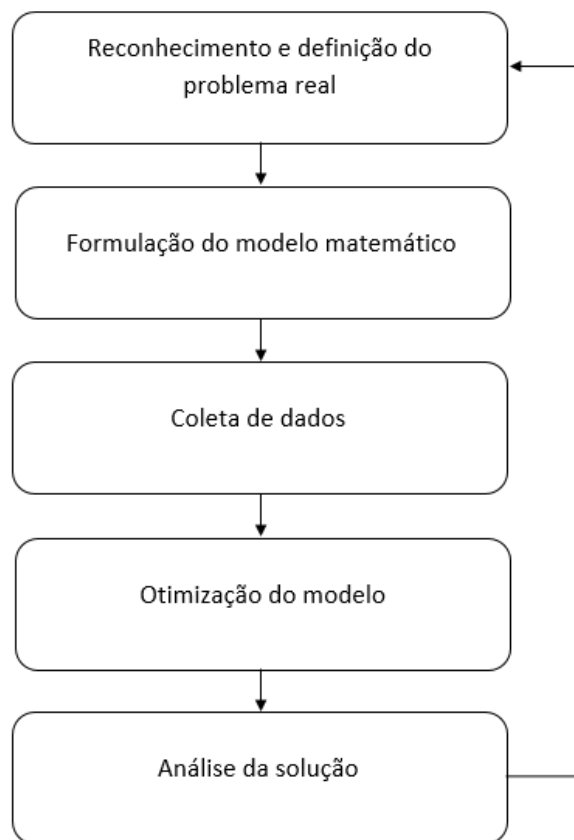


Figura 2.1: Etapas do processo de modelagem. Adaptado de: [40].

Na primeira etapa, deve-se reconhecer a existência de um problema de otimização. O reconhecimento e definição do problema real é muitas vezes o passo mais difícil [88, 40]. Isso acontece pelo fato de muitas vezes se ter que enxergar a existência de diferentes alternativas e que as escolhas podem afetar significativamente o negócio, tornando a tarefa inviável. Na etapa seguinte, o modelador deve formular a função objetivo e o conjunto de restrições de modo a produzir um modelo de otimização.

A terceira etapa consiste na coleta de dados. Algumas dificuldades típicas nesta fase são a falta ou a não disponibilidade de dados [88]. O excesso de informações e a necessidade

de filtros e mineração de dados também podem se apresentar como dificuldades durante a coleta de dados.

Após a formulação do modelo matemático e com os dados coletados e devidamente calibrados e validados, o modelo deve ser traduzido em uma linguagem que seja compreensível para um *solver* apropriado. Para isso, é necessário a utilização de linguagens de modelagem. Estas linguagens são ferramentas de modelagem matemática e computacional [40] que servem para passar o problema e sua representação matemática na forma linguagem de otimização, tornando-o disponível para um *solver* [40, 60].

Existem diversas plataformas de modelagem e simulação de modelos de otimização, as quais utilizam linguagens de modelagem, tais como [1], [4], [45], [81] e [65]. Estas ferramentas geralmente auxiliam na análise de dados. Algumas delas como o [1], possibilita capturar a complexidade de problemas reais, permitindo expressar diversos cálculos complexos de uma maneira compacta, sem preocupação com o gerenciamento de memória ou considerações de estocagem de dados [56].

2.1.1 Programação Linear Inteira Mista

Problemas de Programação Linear têm como característica a distribuição eficiente de recursos limitados entre atividades competitivas [87]. Estes problemas têm como finalidade atender a um determinado objetivo expresso por uma função linear e um conjunto de funções de restrições também lineares sobre os recursos.

De forma geral, um problema de programação linear genérico, pode ser escrito em sua forma matricial como [33, 7]:

$$z = c^T,$$

sujeito a:

$$Ax = b,$$

$$T \geq 0,$$

onde c é um vetor de ordem $(m + n)$, A é uma matriz $m * (m + n)$, x é um vetor coluna de ordem $(m + n)$ e b é um vetor coluna de ordem m . A região factível é formada por todos os pontos que satisfazem simultaneamente as restrições e a função objetivo busca entre esses pontos aquele que minimize o valor de c^T .

Quando as variáveis do modelo passam a assumir valores inteiros, tem-se um problema de Programação Linear Inteira (PLI). Diversos problemas reais possuem propriedades em que suas variáveis podem assumir tanto valores inteiros quanto valores reais. Tais problemas são classificados como problemas de Programação Linear Inteira Mista (PLIM)[107].

Muitos problemas de produção "*scheduling*" são modelados como PLIM. Seus modelos matemáticos de otimização envolvem tanto variáveis contínuas como discretas e devem satisfazer um conjunto de restrições lineares de igualdade e desigualdade[80]. A busca pela solução ótima na resolução de PLIMs pode ser NP-hard, pela sua natureza combinatorial. Em geral, métodos de enumeração são utilizados. Na forma mais simples, estes métodos analisam todos os pontos dentro o espaço de soluções inteiras. Há diversas técnicas para resolução desses problemas, estas variam desde a forma exaustiva, até técnicas consolidadas como a avaliação progressiva *Branch and Bound*[62] e Enumeração Implícita[105].

2.1.2 Problema de Localização de Facilidades

Alguns Problemas de localização de facilidades podem ser classificados como problemas de cobertura e problemas de localização de medianas. Em ambos os problemas, decisões são tomadas sobre onde alocar facilidades, sendo considerados clientes ou unidades de demanda que devem ser servidos de forma a otimizar um dado critério [30]. A maioria dos problemas de localização de facilidades é considerada de difícil solução, alguns desses problemas pertencem à classe NP-hard [5].

Em geral, problemas de localização de facilidades possuem como objetivo a minimização dos custos totais de distribuição mais os custos operacionais das facilidades. Estes problemas são considerados como um processo de planejamento, implementação e controle das operações da cadeia de fornecimento [119].

Um problema de localização de facilidades é considerado multiestágio ou multiperíodo uma vez que as facilidades são assumidas como pré-existentes ou pré-instaladas e o problema

consiste em definir um plano dependente do tempo para a seleção das localizações entre todos os potenciais pré-selecionados [18]. Nesse sentido, uma vez que o horizonte de planeamento é estendido a mais de um período, o problema de localização é dinâmico e é denominado de multiperíodo (em contraste com um problema estático que tem apenas um período).

2.2 Geoprocessamento e Sensoriamento Remoto

Técnicas de Geoprocessamento combinadas ao Sensoriamento Remoto têm sido aplicadas para monitorar, prevenir e combater diversos problemas ambientais de ordem mundial. Em destaque, o aumento da emissão de gases poluentes e do efeito estufa, a escassez dos recursos naturais e de alimentos e também a desertificação [27]. O sensoriamento remoto pode proporcionar uma importante fonte de dados para modelagem desses problemas, que podem ser manipulados e analisados usando um Sistema de Informação Geográfica (*Geographic Information System – GIS*) [13].

A partir do Sensoriamento Remoto, dados são obtidos pelos sistemas sensores de alta resolução temporal e espacial instalados em satélites. Estes sensores são capazes de monitorar a resposta espectral detectada na banda do visível, no infravermelho próximo (*Near Infrared-NIR*) e no infravermelho de ondas curtas (*Short-wavelength infrared – SWIR*).

A medição, análise e interpretação de espectros eletro-ópticos é denominada como espectroscopia [101]. A Figura 2.2 ilustra o conceito de espectroscopia de uma cena capturada a partir da detecção remota por um satélite. Um sensor de imagem no espaço captura simultaneamente múltiplas amostras de faixas de ondas espectrais sobre uma grande área em uma cena de terra. Após processamento apropriado, cada pixel na imagem resultante contém uma amostra da medição espectral de reflectância. Esta amostra pode ser interpretada para identificar o material presente na cena. Os gráficos do lado direito da figura ilustram a variação espectral da reflectância do solo, água e vegetação.

A Tabela 2.1 apresenta como exemplo, características espectrais dos sensores *Operational Land Imager (OLI)* e *Thermal Infrared Sensor (TIRS)*, ambos presentes no satélite em órbita LANDSAT 8, utilizado na pesquisa. As imagens adquiridas por esses sensores consistem em onze bandas espectrais com uma resolução espacial que variam entre 15 e 100 metros quadrados.




Figura 2.2: Ilustração do conceito de espectroscopia. Fonte: [101].

Um catálogo com as combinações de bandas mais utilizadas do LANDSAT 8 para diversas finalidades é disponibilizado pela ESRI¹ e apresentado na Tabela 2.2 como ilustração.

No estudo da desertificação, técnicas de sensoriamento remoto têm sido aplicadas para monitorar as tendências de degradação da terra, através de análises de séries multitemporais dos índices espectrais de vegetação [27]. Estes índices espectrais são transformações aritméticas de bandas espectrais que enfatizam a vegetação e os sinais do solo. A subseção a seguir apresenta uma breve fundamentação teórica sobre desertificação, cujo tema faz parte do escopo do trabalho.

2.2.1 Desertificação

Segundo [90], as terras áridas são particularmente propícias as mudanças de estado, como resultado a escassez, a precipitação variável e a baixa fertilidade do solo. Tais mudanças indesejáveis nas terras áridas frequentemente são descritas com o termo “desertificação”, cuja importância tem sido promovida pela convenção das nações unidas de combate à de-

¹A ESRI (Environmental Systems Research Institute) é uma empresa americana especializada na produção de soluções para a área de informações geográficas, sendo líder mundial em sistemas de informação geográfica. Disponível em: <http://www.esri.com/>

Tabela 2.1: Características espectrais dos instrumentos OLI e TIRS / LANDSAT8.

Bandas	Comprimento de onda (micrômetros)	Resolução (metros)
Banda 1 - Coastal aerosol	0.43-0.45	30
Banda 2 - Blue	0.45-0.51	30
Banda 3 - Green	0.53-0.59	30
Banda 4 - Red	0.64-0.67	30
Banda 5 - Near Infrared	0.85-0.88	30
Banda 6 - SWIR 1	1.57-1.65	30
Banda 7 - SWIR 2	2.11-2.29	30
Banda 8 - Panchromatic	0.50-0.68	15
Banda 9 - Cirrus	1.36-1.38	30
Banda 10 - Thermal Infrared (TIRS) 1	10.60-11.19	100
Banda 11 - Thermal Infrared (TIRS) 2	11.50-12.51	100

sertificação [10]. A Organização das Nações Unidas (ONU)² define desertificação como um fenômeno provocado pela degradação dos solos nas áreas áridas, semiáridas e subúmidas secas, resultante das variações climáticas e das atividades humanas.

O processo da desertificação passou a ser estudado no Brasil nos anos 70 através de um estudo pioneiro realizado pelo ecólogo João Vasconcelos Sobrinho³ que informava que ali estaria a surgir *“um grande deserto com todas as características ecológicas que conduziriam à formação de grandes desertos hoje existentes em outras regiões do globo”* [97, 108]. No Nordeste do Brasil, as condições climáticas e especialmente a intensa evaporação, baixos índices pluviométricos e o uso da terra em meio a falta de políticas públicas agrárias eficientes concorrem para aumentar o risco a de desertificação na região [37]. A Figura 2.3 mostra as áreas brasileiras susceptíveis a desertificação, onde a grande concentração se dá na região Nordeste que possui uma grande área coberta por vegetação semiárida conhecida

²Disponível em: www.un.org/

³João Vasconcelos Sobrinho foi um dos fundadores da Universidade Federal Rural de Pernambuco ao qual também foi reitor (1963). Criou o Jardim Zoobotânico de Dois Irmãos e fundou a Estação Ecológica de Tapacurá. Publicou cerca de 30 livros, todos sobre ecologia e conservação dos recursos naturais. Destacou-se como um dos primeiros cientistas a alertar sobre a formação de desertos em algumas regiões brasileiras - convidado para participar da Conferência das Nações Unidas sobre desertificação em Nairóbi, no Quênia - além de se empenhar na campanha de reflorestamento do pau-brasil.

Tabela 2.2: Catálogo de combinações de bandas LANDSAT 8. Fonte: ESRI.

Uso/Ênfase	Bandas L8 - RGB
Cor Natural	4 3 2
Falsa Cor (urbano)	7 6 4
Cor Infravermelho (vegetação)	5 4 3
Agricultura	6 5 2
Penetração atmosférica	7 6 5
Vegetação saudável	5 6 2
Terra/água	5 6 4
Natural com remoção atmosférica	7 5 3
Ondas curtas infravermelhas	7 5 4
Análise da cobertura vegetal	6 5 4

como caatinga.

É fato que a ação humana também contribui para a evolução no processo de desertificação de grandes áreas em algumas regiões do trópico semiárido brasileiro [27], sobretudo através da utilização de técnicas agropecuárias impróprias, utilização descontrolada de ecossistemas frágeis, queimadas, mineração predatória e desmatamento. Como consequência do processo de desertificação, [23] aponta a relação com ligações climáticas, reduzindo precipitações e seus impactos sobre a adequação de terras para cultivo de subsistência, um dos principais determinantes da migração.

O Instituto Nacional do Semiárido (Insa) tem publicado mapas que delimitam a área dos seis núcleos de desertificação brasileiros que abrangem cerca de 59 municípios e contabilizam cerca de 68.500km² situados na porção semiárida do nordeste brasileiro⁴. Desses seis núcleos, um está localizado no estado pernambucano e compreende os municípios de Cabrobó, Orocó, Santa Maria da Boa Vista, Belém de São Francisco e Floresta [66], que caracterizam-se pela degradação da Caatinga e pela consequente erosão e empobrecimento de solos, decorrentes principalmente do pastejo, do desmatamento e da salinização do solo decorrente de projetos de irrigação em terras inapropriadas, aliados ao contexto climático desfavorável [95].

Pesquisadores vêm demonstrando bastante empenho no estudo do processo de desertificação

⁴Disponível em: <http://www.insa.gov.br/>

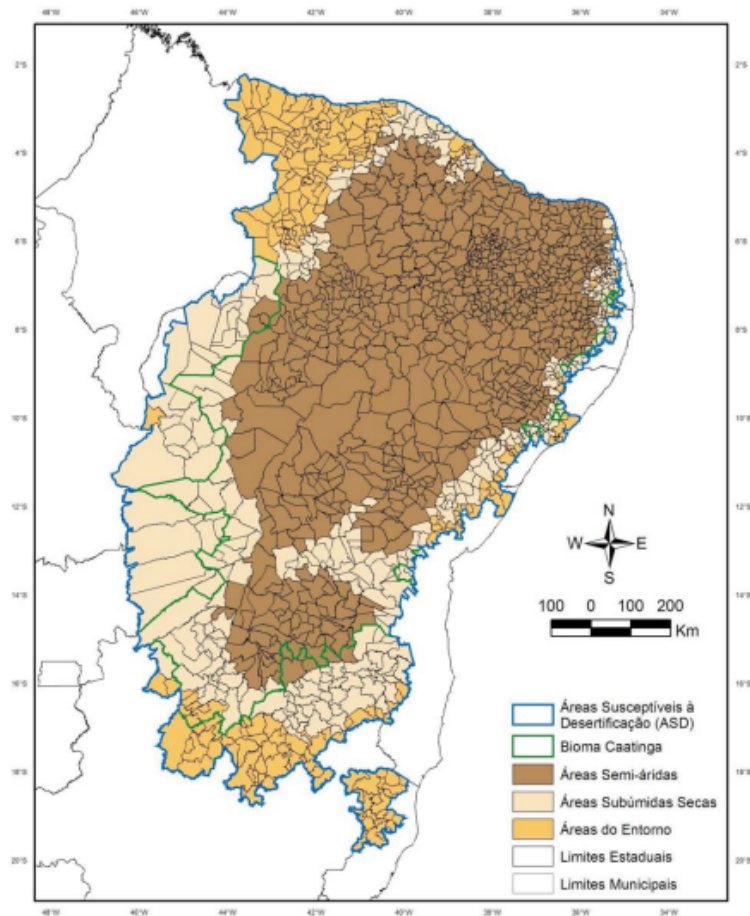


Figura 2.3: Áreas brasileiras susceptíveis ao processo de desertificação. Fonte: [14].

no semiárido brasileiro, realizando estudos para identificar ainda que precocemente, áreas susceptíveis aos processos de desertificação, a fim de que sejam implantados programas que atuem de forma preventiva a estes processos. Na literatura pode-se destacar [76, 104, 6] e no território pernambucano [75, 29, 27, 74, 44] definindo assim um estado da arte no escopo da pesquisa.

Uma maneira de resgatar economicamente essas regiões é através do investimento da expansão de energias renováveis, com o objetivo de reduzir custos e impactos ambientais na etapa de planejamento da expansão de matrizes energéticas.

2.3 Epidemiologia Matemática e Computacional

Uma modelagem matemática pode ser vista como a busca por uma representação matemática para um objeto ou fenômeno que pode ser matemático ou não [36]. Essa modelagem é

abstratamente definida como uma estrutura que está sendo construída para exibir e enaltecer particularidades e características de alguns objetos [111].

Entre as diversas aplicações da modelagem matemática, enquadram-se os estudos de modelos epidemiológicos [59]. No campo da epidemiologia, além da ampla aplicabilidade das técnicas de análise estatística, a modelagem matemática se mostrou útil para a compreensão dos mecanismos de propagação de epidemias e no planejamento de estratégias de controle e avaliação do impacto destas [31].

A necessidade de compreensão da proliferação de doenças do ponto de vista dinâmico, fez surgir uma nova área da ciência: a epidemiologia matemática [118, 77]. Esta área propõe modelos que podem contribuir para projeto e análise de pesquisas epidemiológicas, sugerir qual tipo de dado deve ser coletado, identificar tendências, realizar previsões e estimar a incerteza das previsões [53].

Segundo [3], a epidemiologia matemática difere da maioria das ciências por não prestar-se a validação experimental dos seus modelos. Este fato pode dar uma importância aos modelos matemáticos como uma possível ferramenta para a comparação de estratégias de planejamento de uma epidemia ou pandemia antecipada, e para lidar com um surto de doenças em tempo real.

2.3.1 Modelos Epidemiológicos Compartmentais

A maioria dos modelos epidemiológicos baseiam-se na divisão da população em um pequeno número de compartimentos, cada um contendo os indivíduos que são idênticos em termos do seu estado em relação à doença em causa [3]. Em cada espaço de tempo, um indivíduo pode permanecer no seu estado atual ou mudar de estado e conseqüentemente de compartimento, de acordo com as regras de transmissão da doença em questão. Estes modelos são geralmente escritos como um conjunto de equações diferenciais ordinárias.

Um dos modelos epidemiológicos compartmentais de maior relevância e que mais influenciou no desenvolvimento de modelos matemáticos em epidemiologia foi o modelo SIR (Suscetível - Infectado - Recuperado). Este modelo foi estudado por Kermack e McKendrick, em 1927. Ambos concluíram que um número pequeno de indivíduos infectados, mesmo em contato com indivíduos suscetíveis, não geram uma epidemia [70, 19].

A partir do modelo SIR, diversos outros modelos matemáticos compartimentais passaram a ser construídos e estudados em epidemiologia. O modelo SIR, uma de suas variações, o modelo SIRS e o modelo SIS serão abordados a seguir.

Modelos Epidemiológicos Compartimentais SIR e SIRS

O modelo SIR foi criado para modelar a variação temporal do número de pessoas infectadas por uma doença contagiosa em uma população fechada, ou seja, com um número constante de indivíduos [99]. Este modelo possui uma população numericamente fixa composta por três compartimentos: Suscetíveis (S), Infectados (I) e Recuperados (R).

A suposição básica do modelo SIR é que um indivíduo pode passar sucessivamente por estágios de suscetibilidade, infecção e recuperação e a imunidade é permanente [72]. O fluxo de transição entre os compartimentos é da classe suscetível (S) para a classe de indivíduos infectados (I), e depois, diretamente, para a classe recuperada (R).

Kermack e McKendrick descreveram o modelo SIR, em termos de um sistema não-linear de equações diferenciais ordinárias [51]:

$$\frac{dS}{dt} = -\beta SI,$$

$$\frac{dI}{dt} = \beta SI - \gamma I,$$

$$\frac{dR}{dt} = \gamma I.$$

A taxa de infecção β e a taxa de recuperação média γ são constantes positivas, logo $\beta, \gamma > 0$. As equações diferenciais têm condições iniciais $S(0) = N_1 \geq 0$, $I(0) = N_2 \geq 0$ e $R(0) = N_3 \geq 0$, tal que $N_i \in \mathbb{R}$, $i = 1, 2, 3$ e devem satisfazer a condição $N_1 + N_2 + N_3 = N$, onde N é o número fixo total de indivíduos da população.

Assim, de acordo com [99] temos que:

$$\frac{dS}{dt} + \frac{dI}{dt} + \frac{dR}{dt} = 0$$

Neste modelo, a população é fixa. Logo,

$$S(t) + I(t) + R(t) = N_1 + N_2 + N_3 = N.$$

Os indivíduos estão distribuídos entre os três compartimentos como segue[51]:

- (i) $S(t)$ é a função que representa o número de indivíduos que ainda não foram infectados com a doença no tempo t , ou seja, os que são susceptíveis à doença;
- (ii) $I(t)$ indica o número de indivíduos que foram infectados pela doença no tempo t e que são capazes de transmitir a doença aos da categoria susceptíveis;
- (iii) $R(t)$ é a função do compartimento dos indivíduos que foram infectados e, em seguida, recuperados a partir da doença. Indivíduos desta categoria não são capazes de serem infectados novamente, ou de transmitir a infecção a outros indivíduos.

A transição entre susceptíveis (S) e infectados (I) é β , onde β é a taxa de contato que representa a probabilidade de indivíduos contraírem a doença através um contato entre um indivíduo suscetível e um infeccioso [51]. A transição entre os compartimentos infectados (I) e recuperados (R) é γ que é a taxa de recuperação. A duração de uma infecção é denotada por D , então $\gamma = \frac{1}{D}$, uma vez que o indivíduo alcança a recuperação em unidades de tempo D [51, 15, 82].

O modelo aqui apresentado não contempla dinâmica vital (nascimentos e mortes) e é utilizado quando o ciclo da doença estudada ocorre durante curtos períodos de tempo [89]. No entanto, no estudo de muitas doenças infecciosas, onde a duração é da ordem de meses, ou anos, existe o surgimento de novos indivíduos susceptíveis na população, assim como óbitos também tendem a ocorrer na população. Logo se faz necessário introduzir efeitos demográficos.

Além das taxas β e γ , o modelo SIR com dinâmica vital deve considerar as taxas de natalidade e morte natural. Os indivíduos recém-nascidos estão no compartimento dos susceptíveis. Para garantir a condição de que população total é constante, a taxa de mortalidade é igual a taxa de natalidade.

Ao considerar uma população caracterizada por uma taxa de mortalidade μ , para $\mu > 0$, e uma taxa de natalidade igual à taxa de morte, o sistema de equações diferenciais que representa este modelo SIR é dado por: [51, 15, 82],

$$\frac{dS}{dt} = -\beta SI + \mu(N - S),$$

$$\frac{dI}{dt} = \beta SI - (\gamma + \mu)I,$$

$$\frac{dR}{dt} = \gamma I - \mu R.$$

sendo considerado as condições iniciais $S(0) = N_1 \geq 0$, $I(0) = N_2 \geq 0$ e $R(0) = N_3 \geq 0$, $N_i \in \mathbb{R}$, $i = 1, 2, 3$ satisfazendo a condição $N_1 + N_2 + N_3 = N$.

O modelo compartimental SIRS (Suscetível, Infetado, Recuperado, Suscetível) é derivado a partir do modelo SIR. Este modelo considera a situação em que os indivíduos recuperados perdem a imunidade, após um certo período de tempo, voltando a ser suscetíveis novamente.

Seja δ a taxa de perda de imunidade. Então, como a perda de imunidade é proporcional ao número de indivíduos recuperados, a modelagem do modelo SIRS em relação ao modelo SIR com dinâmica vital apresentado até o momento, é dada por δR , resultando no seguinte sistema de equações diferenciais ordinárias:

$$\frac{dS}{dt} = -\beta SI + \mu(N - S) + \delta R,$$

$$\frac{dI}{dt} = \beta SI - (\gamma + \mu)I,$$

$$\frac{dR}{dt} = \gamma I - (\mu + \delta)R.$$

sendo satisfeitas as mesmas condições iniciais $S(0) = N_1 \geq 0$, $I(0) = N_2 \geq 0$ e $Z(0) = N_3 \geq 0$, $N_i \in \mathbb{R}$, $i = 1, 2, 3$, as taxas $0 \geq \beta, \gamma, \delta \geq 1$, $\mu > 0$ e a condição $N_1 + N_2 + N_3 = N$ para a população total N constante.

Modelos Epidemiológicos Compartmentais SIS

Diferentemente dos modelos SIR e SIRS apresentados anteriormente, o modelo SIS descreve doenças nas quais os indivíduos susceptíveis ao tornarem infectados, após a recuperação, não adquirem imunidade tornando-se susceptíveis novamente.

O modelo SIS sem dinâmica vital, isto é, sem nascimentos e mortes, é dado pelo seguinte sistema de equações diferenciais ordinárias:

$$\frac{dS}{dt} = -\beta SI + \gamma I,$$

$$\frac{dI}{dt} = \beta SI - \gamma I.$$

As equações diferenciais têm condições iniciais $S(0) = N_1 \geq 0$, $I(0) = N_2 \geq 0$ e $Z(0) = N_3 \geq 0$, $N_i \in \mathbb{R}$, $i = 1, 2, 3$. A taxa de de infecção β e a taxa de recuperação média γ são constantes positivas, logo $\beta, \gamma > 0$. Neste modelo, a população é fixa e os indivíduos estão distribuídos entre os três compartimentos como segue[51]:

O modelo SIS sem dinâmica vital é utilizado quando admite-se que a escala temporal da enfermidade é muito rápida quando comparada à dinâmica demográfica da população [89]. Por conta disso, os nascimentos e mortes que ocorrem dentro do curto período de duração da doença são desprezados.

As alterações no modelo para satisfazer a dinâmica vital são realizadas assumindo que o tamanho da população é constante, assim a taxa de nascimentos é igual a de mortalidade.

$$\frac{dS}{dt} = -\beta SI + \mu(N - S) + \gamma I,$$

$$\frac{dI}{dt} = \beta SI - (\gamma + \mu)I.$$

2.4 Autômatos Celulares

Uma variedade de sistemas físicos, biológicos e sociais apresentam comportamento global bastante complexo, ainda que seus componentes fundamentais sejam simples. Esta complexidade global do sistema é atribuída à cooperação conjunta de cada um dos componentes individuais do sistema [114].

Esta classe de sistemas é denominada de sistemas complexos, caracterizados por envolverem não-linearidades [116]. Assim, pequenas alterações podem ter efeitos surpreendentes e que não podem ser entendidos simplesmente por meio da análise dos componentes individuais. Estes efeitos também são difíceis de serem analisados pelos métodos clássicos da matemática ou da física [79].

Uma das abordagens para se estudar o comportamento de sistemas complexos é pelo uso de autômatos celulares [116, 98].

Autômatos celulares (ACs) foram introduzidos por Stanisław Ulam e John von Neumann no final da década de 1940 [109] com o intuito de fornecer uma modelagem e simulação de sistemas complexos capazes de se auto reproduzir. A abordagem proposta oferecia uma nova forma de abordar os problemas concentrando-se em comportamentos locais e em seguida, estudar o comportamento global do sistema [96].

Os autômatos celulares são formalizações matemáticas de sistemas físicos em que o tempo e o espaço são discretos [113]. São compostos por grupos de células em que cada célula é caracterizada pelo estado ao qual se encontra. O estado de cada célula do autômato no próximo instante, depende dos valores das células vizinhas e de um conjunto de regras locais de transição.

A primeira implementação de um autômato celular foi criado por John Conway em 1970, o Jogo da Vida (Game of Life) [24]. O jogo constitui de uma simulação da evolução de um grupo de seres vivos em um reticulado bidimensional. Este autômato celular possui dois estados e regras locais bastante simples. Cada célula "vive" ou "morre" de acordo com as células vizinhas e o jogo tende a convergir para a morte de todas as células ou a geração de padrões estáveis. A Figura 2.4 apresenta uma representação do jogo da vida, onde t representa o período temporal.

A popularização do estudo dos ACs é dada por Stephen Wolfram, que em uma série de




Figura 2.4: Simulação baseada nas regras do Jogo da Vida. Fonte: [67].

artigos [112, 113, 114] mostra ACs como ferramentas simples, porém eficazes na análise de sistemas físicos, biológicos e computacionais. Tais ferramentas mostram-se capazes de tratar e reproduzir comportamentos complicados, gerando padrões espaço-temporais variados e até com características universais [93]. Na literatura, pesquisas e atividades confirmaram que a arquitetura paralela inerente aos ACs fornecem ambientes de simulação computacional de alto desempenho que podem ser usados para resolver problemas do mundo real em ciência e engenharia [106].

2.4.1 Definição

Um Autômato Celular pode ser definido por uma quádrupla de elementos (G, V, Q, f) onde G é o espaço celular (normalmente uma rede regular, tal como \mathbb{Z} ou \mathbb{Z}^2 , $V = \{i_1, \dots, i_s\}$ é a vizinhança (que é geralmente a mesma para todos os locais no espaço celular), Q é um conjunto finito de estados e f é uma função local de transição que associa um novo estado para cada configuração dos estados que compõe a vizinhança, ou seja,

$$f : Q^s \rightarrow Q; (x_1, \dots, x_s) \in Q^s \rightarrow f(x_1, \dots, x_s) \in Q,$$

em que $s = |V|$ é a cardinalidade do conjunto da vizinhança V [73].

Autômatos Celulares são definidos como a evolução dos estados das células que o compõe. O estado de uma célula $\sigma_i^t \in \{0, 1\}$ indica que na posição i no tempo t a célula assume um dos estados definidos, neste caso 0 ou 1. Assumindo uma rede N-dimensional de células, tem-se um Autômato N-dimensional. A função local de transição f , responsável pela evolução dos estados das células é definida como:

$$\sigma_i^{t+1} = f(\sigma_{i-k}^t, \dots, \sigma_i^t, \dots, \sigma_{i+k}^t),$$

em que k é o índice de iterações. A função local de transição é aplicada simultaneamente em todas as células. O estado de uma célula no tempo $t + 1$ das $2k + 1$ células no tempo t , o que constitui sua vizinhança conforme ilustra a figura [2].




Figura 2.5: Representação de uma célula e sua vizinhança. Fonte: [2].

Autômatos celulares são compostos por cinco elementos fundamentais [67, 100]:

- (i) Célula: É considerada a unidade básica do sistema. As células podem ser organizadas em um mosaico espacial que pode ser de uma, duas ou mais dimensões.
- (ii) Estado: Define os atributos do sistema. Cada célula pode apresentar apenas um estado dentro de um conjunto de estados num determinado momento.
- (iii) Vizinhança: É o conjunto de células em que a célula em questão interage. Num espaço bidimensional existem duas tipologias de vizinhança: a vizinhança de von Neumann e a vizinhança de Moore.
- (iv) Regras de Transição: São um conjunto de condições ou funções que definem as alterações de estado de cada célula em resposta a seu estado atual e que de seus vizinhos. O estado futuro de células é determinado pelas regras de transição em um período de tempo discreto.
- (v) Tempo: Especifica a dimensão temporal do autômato celular onde os estados de todas as células são atualizados simultaneamente de modo iterativo ao longo do tempo.

É interessante citar ainda algumas outras propriedades dos ACs, tais como a animação e visualização dinâmica [102]. ACs também possuem o poder de encapsular detalhes específicos e menores que definem o problema no contexto global de acordo com o princípio de pensamento local, ação global. A capacidade de integrar as dimensões espaciais e temporais é outro ponto forte e que torna os ACs atraentes para o desenvolvimento de modelos robustos, confiáveis e de fácil visualização.

2.4.2 Dimensões e formatos

Um Autômato Celular pode ser representado por um vetor unidimensional ou por uma matriz N-dimensional, onde cada célula constituinte é representada por uma posição do vetor ou da matriz. Independentemente da dimensão do AC, cada célula armazena apenas um valor ao qual reflete seu estado. Na Figura 2.6 são mostrados alguns exemplos de formatos de um Autômato Celular e as células que o compõe.




Figura 2.6: Representação de um Autômato Celular: a) unidimensional, b) bidimensional e c) tridimensional. Fonte: [63].

O formato das células que compõe um AC pode possuir diversas geometrias regulares tais como células quadradas, triangulares e hexagonais. Na Figura 2.7 apresentam-se alguns dos formatos mais utilizados.




Figura 2.7: Tipos de formatos das células de um Autômato Celular: a) quadrado, b) hexagonal-Z, c) hexagonal-A e d) triangular. Fonte: adaptado de [120].

2.4.3 Limites e condições de fronteira

As condições de fronteira dependem da especificação física do sistema que está sendo modelado. Tradicionalmente, as células da vizinhança de um local de fronteira variam para diferentes condições de contorno[46]. Assim, devem-se adotar limites de vizinhança das células que compõem a borda do AC, que podem ser:

- (i) Limites periódicos: são obtidos a partir da extensão do autômato, ou seja, as células de uma borda do AC estão conectadas à da borda diametralmente oposta. Exemplificando, as células da borda superior se conectam com as da borda inferior, e as da borda esquerda, com as da borda direita.
- (ii) Fixos: fixam-se os estados das células na borda de um autômato, de modo que independente dos valores da vizinhança das células de fronteira, o valor da mesma permanecerá inalterado.
- (iii) Reflexivos: este limite é a condição de contorno obtida refletindo-se o autômato em cada borda. Ou seja, no lugar da célula ausente na vizinhança, é utilizada uma cópia da célula interna desta mesma vizinhança.

2.4.4 Vizinhança e regras de transição

Para que ocorra a evolução dos ACs, é necessário que sejam definidas as células vizinhas. A função da vizinhança é definir o estado das células no próximo instante de tempo [79]. Cabe as regras locais de transição, atualizar o valor de cada célula da rede, com base nos valores das células que compõem a vizinhança do local[46], de acordo com o tipo de vizinhança e as condições de fronteira.

No caso de um autômato unidimensional, composto por um único vetor de células, o mais comum é considerar que cada célula possui duas vizinhas, uma à esquerda e outra à direita. Considerando um autômato celular elementar unidimensional [115], onde uma célula pode assumir apenas dois estados, sua vizinhança é constituída pela própria célula e suas adjacentes a esquerda e a direita, formando uma vizinhança de três células. Assim, para um AC elementar, $2^3 = 8$ tipos de vizinhança de tamanho três podem ser definidas, resultando em $2^8 = 256$ regras de transição distintas.

No caso dos ACs bidimensionais, é possível definir diferentes tipos de vizinhança tais como a de Von Neumann e a vizinhança de Moore. Na vizinhança de Von Neumann de raio unitário, cada célula é conectada às quatro adjacentes na vertical e na horizontal. A vizinhança de Von Neumann de raio r de uma célula abrange as células dispostas ortogonalmente até a distância r desta célula. A vizinhança de Moore de raio r de uma célula é composta pela matriz quadrada de lado $2r + 1$ centrada na célula em questão.

A vizinhança de Moore é composta das oito células adjacentes, considerando as células verticais, horizontais e diagonais [52].

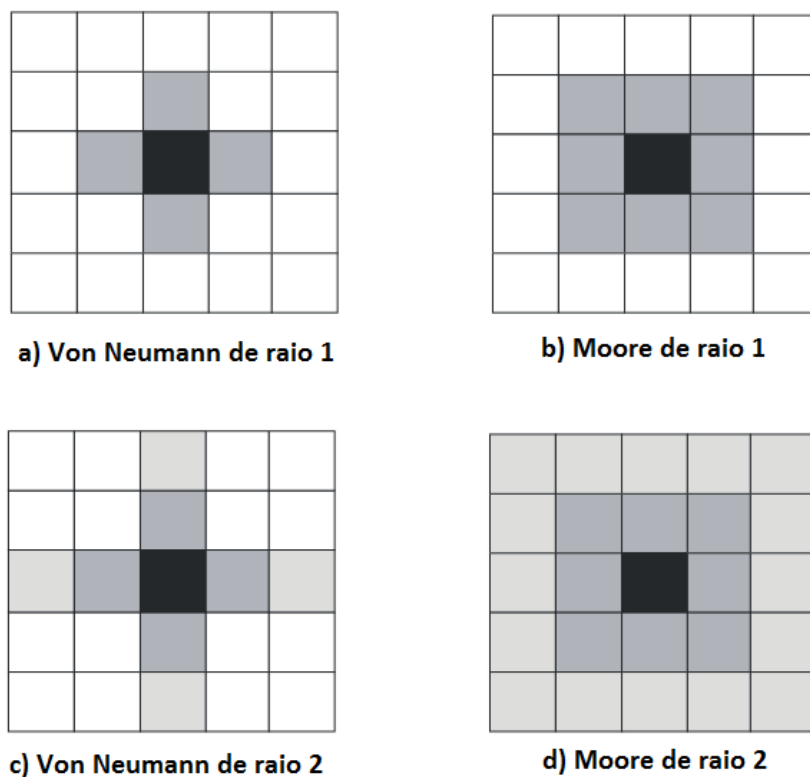


Figura 2.8: Representação das vizinhanças de a) Von Neumann de raio 1, b) Moore de raio 1, c) Von Neumann de raio 2 e d) Moore de raio 2.

2.4.5 Discretização de Modelos Epidemiológicos utilizando Autômatos celulares

A modelagem de epidemias é um processo que exhibe comportamento complexo ao longo do tempo [57]. Tradicionalmente, a maioria dos modelos matemáticos existentes para simular epidemias são baseados em equações diferenciais ordinárias. Estes modelos, incluindo os

modelos compartimentais vistos na subseção 2.3.1, têm como característica a distribuição de indivíduos espacial e temporalmente homogênea [53].

Neste sentido, apenas com a utilização de modelos epidemiológicos baseados em equações diferenciais para descrever epidemias, não é possível simular de forma adequada [110]: (i) os processos individuais de contatos; (ii) os efeitos do comportamento individual da população; (iii) os aspectos espaciais da epidemia; e (iv) os efeitos da mistura de padrões dos indivíduos.

Segundo [99], a heterogeneidade pode ser modelada por meio de técnicas existentes na literatura em que as interações entre indivíduos são consideradas. Entre essas técnicas, os Autômatos Celulares têm sido objeto de estudos de diversos trabalhos relacionados a modelagem de sistemas epidemiológicos [103]. Entre estes trabalhos é importante destacar [12, 42, 92, 43] e os mais recentes [54, 34].

A utilização de ACs para modelagem e simulação de epidemias considera os indivíduos distribuídos no espaço celular de tal modo que cada célula representa um indivíduo da população [110]. Esta técnica permite que sejam definidos sistemas dinâmicos discretos onde o comportamento é especificado em termos das relações locais [78], sendo possível determinar como as interações locais podem influenciar o comportamento global do sistema.

Capítulo 3

Configuração do Modelo

O objetivo da metodologia aqui construída é mostrar que é possível definir e modelar um simulador computacional baseado em autômatos celulares que venha a dar suporte no gerenciamento de recursos de energia.

A Seção 3.1 utiliza Programação Linear Inteira Mista para resolução do problema dos despachos em tempo real de usinas térmicas em um sistema hidrotérmico. O problema é modelado como um problema de localização de facilidades, levando em consideração algumas particularidades do modelo energético brasileiro. No Brasil, os geradores, de modo geral, não detêm autonomia para despachar a geração. Compete ao Operador Nacional do Sistema (ONS), determinar quanto cada usina deve produzir a cada momento, levando em conta as exigências de suficiência e de economicidade no atendimento da demanda. Esta dimensão irá fornecer ao simulador, a configuração ótima do acionamento das usinas térmicas por período de tempo. Essa configuração deve satisfazer a carga de demanda de um sistema hidrotérmico, além de fornecer informações de carga de intercâmbios de entre seus subsistemas.

Para a construção desse trabalho, optou-se por um escopo que abordasse as atividades de geração, transmissão e distribuição de energia elétrica. Também procurou-se levar em consideração aspectos ambientais que influenciam no planejamento da expansão de matrizes energéticas e linhas de transmissão. Nesse sentido, é apresentada uma metodologia para geração de mapas de níveis de susceptibilidade do solo ao processo de desertificação na Seção 3.2. Estes mapas gerados, compõem uma das dimensões do simulador, fornecendo informações de regiões classificadas por nível de susceptibilidade do solo.

Motivado pelo conceito denominado de *Energy Epidemiology*, proposto pelo Instituto de Energia do Reino Unido e apresentado em [50], são apresentadas na Seção 3.3 interpretações baseadas nos modelos epidemiológicos compartimentais SIRS e SIS que irão compor duas dimensões do simulador. A primeira dimensão, baseada modelo SIRS, tem o objetivo de prever cenários de alterações de crescimento de demanda da população em um período de tempo. Por sua vez, a segunda abordagem irá modelar o processo de distribuição de energia tomando como base para modelagem, o modelo SIS.

O simulador é apresentado na Seção 3.4, unindo todas as dimensões criadas. Nessa seção, será introduzida a forma como as dimensões de entrada compõem o simulador. Também serão definidas as regras de transição das dimensões baseadas nos modelos epidemiológicos compartimentais, como forma de obter a heterogeneidade da distribuição dos indivíduos no sistema. Ao final da seção, será apresentado o algoritmo do funcionamento do simulador.

3.1 Modelagem de Otimização para despacho de usinas térmicas em sistemas hidrotérmicos

3.1.1 Contextualização e descrição do problema

Um sistema hidrotérmico (Figura 3.1) é constituído de usinas hidrelétricas, usinas térmicas, usinas de geração complementar – em geral, pequenas usinas considerando o MW médio (e.g. eólicas e solares) – e uma rede de transmissão interligando as usinas com os centros de carga. Um sistema hidrotérmico interligado de grande porte pode ser dividido em subsistemas menores para facilitar sua operação adotando critérios associados à posição geográfica das principais linhas de transmissão e das bacias hidrográficas. Nesse tipo de sistema, também são permitidos intercâmbios entre subsistemas e importações de energia entre os sistemas vizinhos.

Um sistema hidrotérmico tem custo de operação a complementação do acionamento das usinas térmicas. O reflexo desse custo dentro do sistema é inversamente proporcional a utilização das fontes hidrelétricas. Isso se dá devido ao fato da energia gerada por fontes hidrelétricas ser renovável e por isso possuir baixo custo de operação quando seus ativos já estão totalmente amortizados. A utilização de usinas térmicas tem seus custos de geração

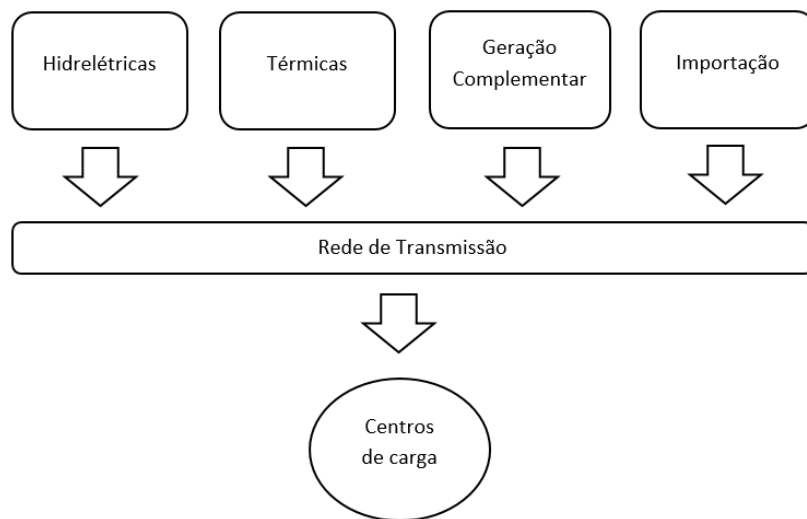


Figura 3.1: Representação de um sistema hidrotérmico genérico.

maiores devido aos combustíveis não renováveis associados.

A geração complementar proveniente de parques eólicos e solares servem como complementação da geração de energia elétrica do sistema, já que dependem de parâmetros como incidências de ventos e radiação solar aos quais tem restrições de disponibilidade. Estas fontes de geração desempenham um papel de ajudar a economizar água dos reservatórios e evitar o despacho de térmicas que são mais poluentes e onerosas.

No Brasil, a maior parte da geração, linhas de transmissão, distribuição e consumo de energia estão interconectados, em um ambiente regulado a um único sistema, o Sistema Interligado Nacional (SIN), o que permite a complementaridade energética entre diferentes fontes e regiões. O SIN é ilustrado na Figura 3.2. O ONS é a instituição responsável por coordenar a operação eletroenergética das usinas do SIN. É de competência do ONS decidir a produção de energia nos diferentes geradores do sistema, com o objetivo de otimizar o uso da água armazenada das hidrelétricas, minimizar os custos de operação das térmicas e garantir a disponibilidade de energia.

O planejamento da operação do sistema é realizado com perspectiva em diversos horizontes. No horizonte a curto prazo, o planejamento é baseado na programação da operação. É necessário nesse horizonte, obter uma política de operação por usina a fim de realizar o despacho ótimo das geradoras para o atendimento aos requisitos de carga demandados, a cada intervalo de tempo, ao mínimo custo, preservando a confiabilidade da operação elétrica.



Figura 3.2: Representação do SIN. Adaptado de: [69]

Embora o projeto NEWAVE [71] e o modelo DECOMP [26] sejam utilizados pela Câmara de Comercialização de Energia Elétrica (CCEE) e pelo Operador Nacional do Sistema Elétrico (ONS) nas etapas de planejamento a curto e médio prazo, estes não fornecem configurações do despacho ótimo da operação diária do SIN.

Neste sentido, a subseção seguinte utiliza da modelagem matemática de otimização para apresentação de uma proposta de resolução do problema de gerenciamento diário do despacho das usinas térmicas, considerando a demanda horária dos quatro principais subsistemas do SIN. O objetivo da apresentação desse modelo é fornecer para o simulador o balanço em tempo real da geração de carga e realização de intercâmbios com a demanda dos subsistemas. Essa dimensão que fornecerá dados importantes como entrada para o simulador de forma que o auxilie e ao operador de tempo real, na determinação de como agir durante a realização do despacho das usinas térmicas.

3.1.2 Modelagem Matemática

A modelagem matemática de otimização foi realizada através da construção de um modelo multiperíodo de localização de facilidades. Para cada subsistema de energia elétrica, com demanda conhecida, há um número de locais alternativos onde potenciais facilidades de

geração térmica de energia podem ser acionadas para entrar em operação. A demanda de todo o sistema deve ser atendida em sua totalidade sobre os variados períodos de tempo. Para a construção do modelo, foi tomado como base o setor de energia elétrica brasileiro, sendo considerados seus aspectos regulatórios sempre que possível. Foi considerado que alguns contratos de concessão das usinas térmicas estabelecem obrigatoriedade de geração mínima para garantir a estabilidade da rede elétrica e a disponibilidade do recurso. Por ser obrigatório, não foi atribuído custo de operação a parcela inflexível da geração térmica. O mesmo acontece com a energia adquirida por importação que também possui valor fixado em contrato.

São atribuídos custos para a geração térmica adicional e custos para intercâmbios entre subsistemas. Por se tratarem de fontes de energia renováveis, não foram atribuídos custos de operação para as gerações hidráulica e complementar.

O modelo de otimização deve determinar o número de facilidades térmicas presentes em cada subsistema que devem ser despachadas em cada período de tempo, além de prover intercâmbios entre os subsistemas. O objetivo do modelo é atender a demanda do subsistema, efetuando o despacho ótimo com os custos de operação e de intercâmbio minimizados.

Fazem parte do modelo os seguintes conjuntos "sets":

T – Conjunto de períodos de tempo com $a = |T|$;

LT – Conjunto de localizações térmicas candidatas para facilidades com $b = |LT|$;

LH – Conjunto de localizações hidrelétricas candidatas para facilidades com $c = |LH|$;

LC – Conjunto de localizações complementares candidatas para facilidades com $d = |LC|$;

S – Conjunto de subsistemas elétricos com $e = |S|$.

Os parâmetros do modelo são:

$ot_{i,k}$ – Custo de operação da facilidade térmica $i \in LT$ pertencente ao subsistema $k \in S$. Reflete o custo para se gerar cada MW/h em cada usina térmica do subsistema. Esse custo varia de acordo com o valor do combustível fóssil ou nuclear utilizado por cada usina térmica;

d_k^t – Demanda energética do subsistema $k \in S$ no período de tempo $t \in T$. Corresponde a toda a carga demandada pelo subsistema;

$ct_{i,k}$ – Capacidade instalada da facilidade térmica $i \in LT$ pertencente ao subsistema $k \in S$. Ou seja, é o limite máximo de produção de cada usina térmica;

$gtmin_{i,k}$ – Geração mínima da facilidade térmica $i \in LT$ pertencente ao subsistema $k \in S$. Este parâmetro corresponde a parcela de geração das usinas térmicas considerada inflexível. Este valor que é obrigatório e está presente no contrato de concessão de algumas usinas, serve para garantir a estabilidade e a disponibilidade da rede dentro do subsistema;

$ftmax_{i,k}$ – Fator de capacidade máxima da facilidade térmica $i \in LT$ pertencente ao subsistema $k \in S$. Este parâmetro traz o fator máximo viável para a geração de cada usina térmica;

$gh_{l,k}$ – Capacidade de geração disponível da facilidade hidrelétrica $l \in LH$ pertencente ao subsistema $k \in S$;

$gc_{m,k}$ – Capacidade de geração média das facilidades complementares $m \in LC$ pertencente ao subsistema $k \in S$;

imp_k – Carga de energia importada pelo subsistema $k \in S$. Parcela de carga correspondente a energia recebida de fora do subsistema considerado;

cp – Fator de perdas no intercâmbio. Este parâmetro é utilizado para calcular as perdas no intercâmbio de fornecimento de energia entre os subsistemas;

$cint$ – Custo unitário (MW/h) médio para realização de intercâmbio entre subsistemas.

Variáveis de decisão:

$$yt_{i,k}^t = \begin{cases} 1, & \text{se a facilidade térmica em } i \in LT \text{ pertencente ao subsistema } k \in S \text{ operar} \\ & \text{dentro do período } t \in T, \\ 0, & \text{caso contrário.} \end{cases}$$

$qta_{i,k}^t$ – Quantidade de energia adicional gerada pela facilidade térmica $i \in LT$ pertencente ao subsistema $k \in S$ no período $t \in T$.

if_k^t – Quantidade de energia fornecida pelo intercâmbio do subsistema $k \in S$ no período $t \in T$.

ir_k^t – Quantidade de energia recebida pelo intercâmbio do subsistema $k \in S$ no período $t \in T$.

As variáveis $qta_{i,k}^t$, if_k^t e ir_k^t , todas não negativas, irão armazenar a carga flexível gerada por cada usina térmica e as quantidade de energia fornecidas e recebidas por cada subsistema via intercâmbio, respectivamente.

Vale a pena ressaltar que não há necessidade de uma variável para o acionamento das geradoras hidrelétricas e complementares por estas estarem sempre em operação de acordo com sua disponibilidade.

Função Objetivo:

$$\min \sum_{t \in T} \left(\left(\sum_{k \in S} \sum_{i \in LT} ot_{i,k} * qta_{i,k}^t * yt_{i,k}^t \right) + \left(\sum_{k \in S} cint * (if_k^t + p_k^t) \right) \right) \quad (3.1)$$

A função objetivo 3.1 representa em cada período de tempo a minimização dos custos geração térmica adicional das fontes acionadas somado aos custos de intercâmbio de energia e suas perdas.

Restrições:

$$d_k^t \leq \sum_{l \in LH} gh_{l,k} + \sum_{m \in LC} gc_{m,k} + \sum_{i \in LT} (gtmin_{i,k} + qta_{i,k}^t) + ir_k^t - if_k^t - p_k^t + imp_k \quad t \in T, k \in S, \quad (3.2)$$

A restrição 3.2 corresponde ao balanço de energia de cada subsistema. Este balanço consiste em atender a carga da demanda com a geração de energia obtida pelas variáveis das fontes de energia, e os intercâmbios entre subsistemas vizinhos, além das importações de cada subsistema. Assim, para cada período, a demanda do subsistema deve ser igual à soma de toda a geração hidrelétrica do subsistema mais a geração complementar, térmica (incluindo a parte inflexível e adicional) somados os intercâmbios recebidos de outros subsistemas e as importações e subtraídos a energia referente ao intercâmbio fornecido e as perdas de intercâmbio.

$$\begin{aligned} \sum_{k \in S} d_k^t \leq & \sum_{l \in LH} \sum_{k \in S} gh_{l,k} + \sum_{m \in LC} \sum_{k \in S} gc_{m,k} + \sum_{i \in LT} \sum_{k \in S} (ct_{i,k} + qta_{i,k}^t) + \sum_{k \in S} ir_k^t \\ & - \sum_{k \in S} if_k^t - \sum_{k \in S} p_k^t + \sum_{k \in S} imp_k \end{aligned} \quad t \in T, k \in S, \quad (3.3)$$

O balanço completo do sistema é dado pela restrição 3.3. Esta restrição consiste em satisfazer toda demanda dos subsistemas através da geração de suas fontes, da carga recebida por intercâmbios e importações, considerando a subtração do fornecimento e perdas de intercâmbios. A equação é descrita de maneira análoga a Restrição 3.2 que realiza o balanço para cada subsistema.

$$p_k^t = if_k^t * cp, \quad t \in T, k \in S, \quad (3.4)$$

O valor das perdas com intercâmbio de cada subsistema é calculado pela restrição 3.4. As perdas em (*MWh*) são definidas pela quantidade de energia fornecida para outro subsistema multiplicado com coeficiente de perda.

$$\sum_{k \in S} if_k^t = \sum_{k \in S} ir_k^t + \sum_{k \in S} p_k^t \quad t \in T, k \in S, \quad (3.5)$$

O balanço dos intercâmbios é estabelecido pela restrição 3.5 onde o total de fornecimento de todos os subsistemas deve ser igual ao recebimento considerando também as perdas de transmissão durante o intercâmbio.

$$qta_{i,k}^t \geq (ct_{i,k} * ftmax_{i,k}) - gtmin_{i,k} \quad t \in T, k \in S, i \in LT, \quad (3.6)$$

A restrição 3.6 define que a quantidade adicional de geração térmica das usinas pertencentes a cada subsistema em cada período deve ser maior ou igual a capacidade instalada multiplicado a fator de capacidade máxima subtraída a parte de geração inflexível.

$$qta_{i,k}^t \geq 0, \quad t \in T, k \in S, i \in LT, \quad (3.7)$$

$$if_k^t \geq 0, \quad t \in T, t \in T, k \in S, \quad (3.8)$$

$$ir_k^t \geq 0, \quad t \in T, k \in S, \quad (3.9)$$

As restrições 3.7, 3.8 e 3.9 são de não negatividade para as variáveis quantidade de energia térmica adicional e quantidade de intercâmbio fornecido e recebido pelos subsistemas.

$$yt_{i,k}^t \in \{0, 1\}, \quad t \in T, k \in S, i \in LT. \quad (3.10)$$

A restrição 3.10 indica que a variável responsável por indicar o acionamento das usinas térmicas é binária.

A resolução deste modelo e a simulação da operação utilizando dados reais do Sistema Interligado Nacional é apresentado como resultado no próximo capítulo.

3.2 Geração de Mapas de Susceptibilidade de Solos por Geoprocessamento e Sensoriamento Remoto

Esta etapa da pesquisa constituiu da definição de uma metodologia para geração de mapas autonavegáveis de níveis de susceptibilidade de solos ao processo de desertificação. A navegabilidade é obtida pelo nível de representatividade dos mapas gerados. Este mapas

possuem alta resolução devido ao fato de serem contruídos a partir de mosaicos de imagens capturadas por satélites e atingem diversos níveis de *zoom* sem perda de qualidade. Os mapas são gerados pelas composições de diversas cenas capturadas por um mesmo satélite. Cada cena gerada tem um poder de representatividade de $185km^2$ e uma resolução de $30m^2$ por pixel.

A construção dos mapas de susceptibilidade faz parte do projeto *Desert-MAP*, a *software plataform*¹, vinculado ao grupo de pesquisa INES em parceria com o Instituto SENAI de Inovação para Tecnologias da Informação e Comunicação (ISI-TICs) e o Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq). Toda a pesquisa descrita nesta seção foi desenvolvida no Laboratório de Geoprocessamento e Sensoriamento Remoto (GEOSERE) da Universidade Federal Rural de Pernambuco (UFRPE), ambos também parceiros do projeto.

A metodologia que será aqui apresentada irá considerar as particularidades relativas ao processo de desertificação para geração de mapas que reflitam os níveis de susceptibilidade das regiões. No entanto, o objetivo é que esta metodologia seja escalável e que também possa auxiliar na prevenção e combate a diversos outros problemas ambientais através da inserção de suas particularidades.

Os mapas de susceptibilidade gerados podem influenciar na redução de custos e impactos ambientais na etapa de planejamento da expansão de matrizes energéticas, como destaque a de fontes renováveis, além da expansão de linhas de transmissão. Energias renováveis que já vem se beneficiando com o emergente comércio de créditos de carbono no mercado mundial [83].

Ainda pouco explorado, o Brasil possui alto índice de radiação solar, principalmente na região Nordeste, mais especificadamente no semiárido onde encontram-se as regiões com maior susceptibilidade ao processo de desertificação. Os valores típicos anuais de radiação incidente neste locais são de 1.752 a $2.190kWh/m^2$ [85]. A utilização de placas solares fotovoltaicas nas regiões de baixa fertilidade é uma alternativa bastante viável ambientalmente e até economicamente se considerados tais problemas ambientais. Segundo [84], para cada um metro quadrado de coletor solar instalado evita-se a inundação de $56m^2$ de terras férteis, na construção de novas usinas hidrelétricas, por exemplo.

Neste trabalho, o resultado da classificação das áreas de susceptibilidade irá compor a di-

¹Uma visão em: <http://www.ines.org.br/?p=779>

mensão de coleta de dados por Geoprocessamento e Sensoriamento Remoto do simulador. Todo o mapa gerado nessa dimensão irá assumir o formato de autômato celular, onde os estados de cada célula irão fornecer dados referente a classificação de susceptibilidade da região para que possa auxiliar a nível de gestão no processo de planejamento e expansão de matriz energética e linhas de transmissão.

A metodologia desenvolvida para construção dos mapas de susceptibilidade foi dividida em quatro etapas conforme ilustra a Figura 3.3. A primeira trata-se da etapa de aquisição, seguida pelas etapas de pré-processamento, processamento e extração de informações. As subseções seguintes irão discutir cada uma das etapas descritas.

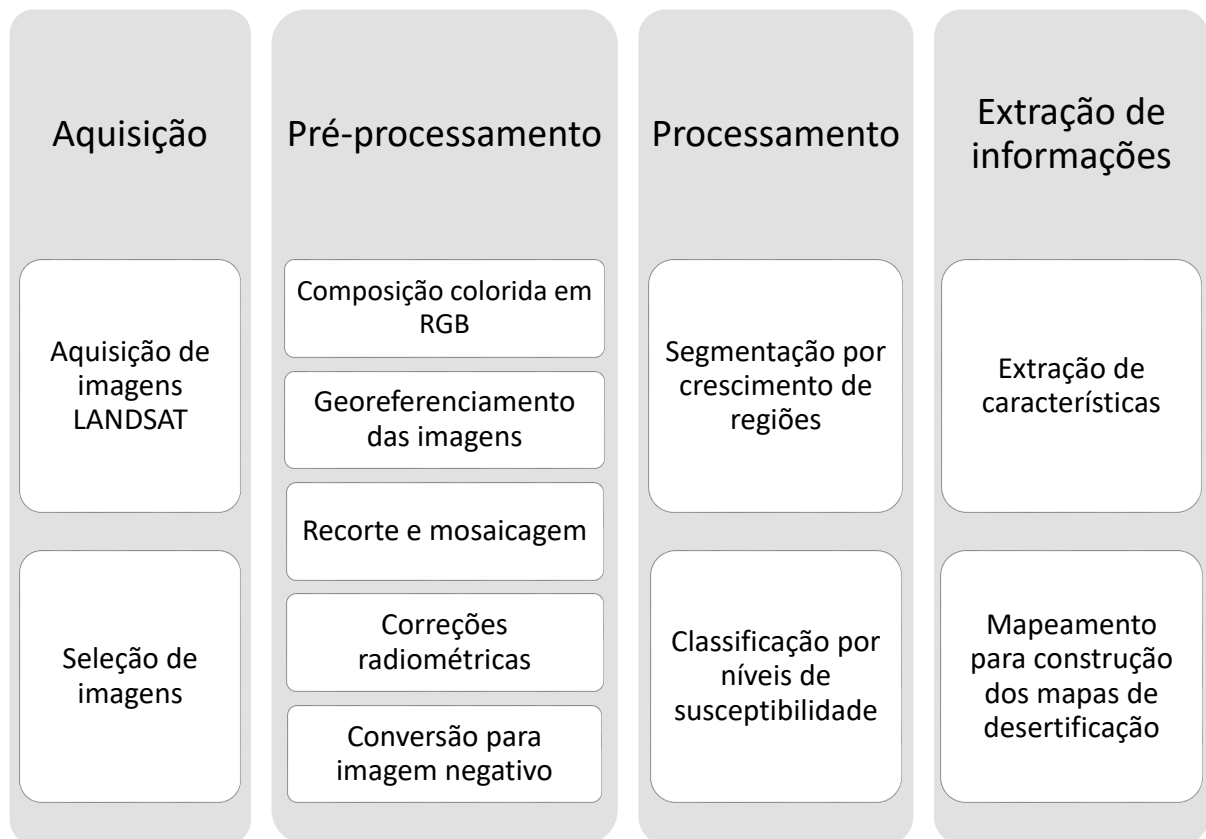


Figura 3.3: Fluxograma da metodologia para geração de mapas de susceptibilidade de solos ao processo de desertificação.

3.2.1 Aquisição de imagens

Nessa etapa, são adquiridas imagens relativas as cenas da área de estudo em uma determinada época. Durante a fase de seleção, os requisitos adotados foram:

1. A menor cobertura possível de nuvens nas cenas utilizadas;
2. As datas de aquisição das imagens que irão compor o mosaico deverá ser próxima.
3. A compatibilidade das resoluções radiométricas entre as cenas que irão compor o mosaico.
4. A qualidade do pré-processamento das imagens coletadas.

Durante a pesquisa, foram utilizadas imagens da série histórica dos sensores OLI/LANDSAT 8 e TM/LANDSAT 5 referentes aos anos de 2004 e 2015. O ano de 2004 foi escolhido para poder ser efetuada a validação dos resultados, devido a referência base do estudo [87], ter gerados mapas utilizando o sensor TM/LANDSAT 5.

As imagens foram adquiridas através dos bancos de dados do Instituto Nacional de Pesquisas Espaciais (INPE) e do *United States Geological Survey* (USGS). As cenas possuem resolução radiométrica de 8 bits para o sensor TM e 16 bits para o OLI. Durante esta etapa, foram adquiridos 69 pacotes de imagens para seleção, totalizando 45,31 Gigabytes de informações.

Na Tabela 3.1 são apresentas informações das imagens utilizadas. As demais foram descartadas durante a etapa de seleção por não atenderem aos requisitos necessários para as demais etapas da metodologia.

3.2.2 Pré-processamento

Na etapa de pré-processamento, são realizadas as composições de bandas das imagens, georeferenciamento e mosaicagem, além da aplicação das correções radiométricas. Para auxiliar nessa etapa, foram utilizados os softwares SPRING² (Sistema de Processamento de Informações Georreferenciadas), do Instituto Nacional de Pesquisas Espaciais - INPE e o QGIS³, ambos são Sistemas de Informações Geográficas (SIGs).

Foram geradas composições coloridas com base em três bandas espectrais dos sensores OLI/LANDSAT 8 e TM/LANDSAT5, levando em consideração as bandas que fornecem uma melhor percepção do objeto de estudo. Para cada banda, foi associada uma cor primária de forma que para o sensor TM a banda 5 representou o canal Red, a banda 3 o canal Green e

²Disponível em: <http://www.dpi.inpe.br/spring/>

³Disponível em: <http://www.qgis.org/>

Tabela 3.1: Imagens do Satélite LANDSAT utilizadas na Pesquisa.

Satélite/Sensor	Órbita/Ponto	Bandas Espectrais	Data de aquisição
LANDSAT 5 (TM)	215/65	5, 3 e 2	10/07/2004
LANDSAT 5 (TM)	215/66	5, 3 e 2	10/07/2004
LANDSAT 5 (TM)	216/65	5, 3 e 2	17/12/2004
LANDSAT 5 (TM)	216/66	5, 3 e 2	24/12/2004
LANDSAT 5 (TM)	217/65	5, 3 e 2	12/10/2004
LANDSAT 5 (TM)	217/66	5, 3 e 2	13/11/2004
LANDSAT 5 (TM)	218/65	5, 3 e 2	17/09/2004
LANDSAT 5 (TM)	218/66	5, 3 e 2	17/09/2004
LANDSAT 8 (OLI)	215/65	6, 4 e 3	10/05/2015
LANDSAT 8 (OLI)	215/66	6, 4 e 3	10/05/2015
LANDSAT 8 (OLI)	216/65	6, 4 e 3	05/11/2015
LANDSAT 8 (OLI)	216/66	6, 4 e 3	05/11/2015
LANDSAT 8 (OLI)	217/65	6, 4 e 3	12/11/2015
LANDSAT 8 (OLI)	217/66	6, 4 e 3	12/11/2015
LANDSAT 8 (OLI)	218/65	6, 4 e 3	03/11/2015
LANDSAT 8 (OLI)	218/66	6, 4 e 3	03/11/2015

a banda 2 o canal Blue. Para o sensor OLI, a composição foi realizada pelas bandas 6 (R), 4 (G) e 3 (B).

As imagens foram adquiridas pré-georeferenciadas através do *Earth Science Data Interface* (ESDI) da *Global Land Cover Facility*. Estas foram importadas e inseridas em um banco de dados. O sistema de projeção cartográfica utilizado foi UTM/Datum ITRF(WGS84). Considerando que foram utilizadas imagens de diferentes épocas onde as respostas espectrais são influenciadas principalmente pelas condições climáticas, a mosaicagem das imagens LANDSAT TM foi realizada de tal forma que as diferenças de radiometrias fossem minimizadas. Neste sentido, também foram aplicadas correções radiométricas às imagens georeferenciadas através de realce de contraste e equalização de histograma para melhoria da qualidade visual após a mosaicagem.

Também foi aplicado o filtro negativo que é um mapeamento linear inverso que representa o efeito da inversão de contraste sobre o histograma. A utilização de imagens negativo

facilita a discriminação da resposta espectral nos alvos na imagem para identificar as áreas degradadas e é tradicionalmente utilizado na literatura [29, 27, 28].

3.2.3 Processamento e extração de informações

A primeira etapa da fase de processamento de imagens envolve segmentação. Algoritmos de segmentação baseados em regiões tem por objetivo agrupar pixels usando a propriedade de semelhança com base em determinados critérios de homogeneidade [16]. A maioria desses métodos baseiam-se no convencional crescimento de regiões [48] e na morfológica transformação de bacias [64].

Nesta etapa foi utilizada a segmentação baseada em crescimento de regiões que é um processo iterativo pelo qual as regiões são mescladas a partir de pixels individuais ou de uma segmentação inicial que vai crescendo de forma iterativa. Foi feito uso do algoritmo de segmentação implementado no SPRING que segue os passos de [11], obedecendo as seguintes etapas:

Algorithm 1 Segmentação por crescimento de regiões.

- 1: Toda a imagem é decomposta em segmentos ou células padrão (um ou mais pixels);
 - 2: Cada célula padrão é comparada com os seus vizinhos para determinar se são semelhantes, usando uma medida de similaridade. Se estas são semelhantes, as células devem ser mescladas para formar um fragmento e atualizar a propriedade utilizada na comparação;
 - 3: Continua-se crescendo o fragmento, examinando todos os seus vizinhos até que não se possa unir mais regiões. Feito isso é rotulado o fragmento como uma região concluída;
 - 4: Move-se então para a próxima célula incompleta, e repete-se estes passos até que todas as células sejam etiquetadas.
-

A etapa de segmentação foi adotada na metodologia para dar suporte a etapa de classificação que constitui na análise de pixels de forma isolada e apresenta uma limitação por tomar como base apenas atributos espectrais. Na adoção do processo de segmentação, os objetos relevantes serão extraídos para compor as regiões de interesse da imagem com base em pixels contíguos que se espalham bidirecionalmente e que apresentam uniformidade.

A etapa de classificação consiste no reconhecimento de padrões e objetos homogêneos a fim de mapear áreas da superfície terrestre que correspondem ao nosso tema de interesse. Nesse processo, a informação espectral de uma cena pode ser representada por uma imagem

espectral, na qual cada *pixel* tem coordenadas espaciais x, y e uma espectral L , que representa a radiância do alvo em todas as bandas espectrais, ou seja para uma imagem de K bandas, existem K níveis de cinza associados a cada pixel sendo um para cada banda espectral. O conjunto de características espectrais de um *pixel* é denotado pelo termo atributos espectrais [17].

Os parâmetros da classificação tomaram como base os valores da leitura de pixels do SIG SOLODESERT (Sistema de Informações Geográficas SOLODESERT)[27]. Este SIG caracteriza níveis de degradação do solo a partir das informações geradas por imagens negativo, cálculo do *Normalized Difference Vegetation Index* (NDVI) e vetorização de áreas para solos sob risco de processos de desertificação no semiárido pernambucano. O autor em sua pesquisa utilizou das unidades de mapeamento da Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA) e considerou principalmente os atributos e características dos solos, relevo, risco à erosão e a presença de solos suscetíveis a desertificação na unidade de sua área de estudo para construção de um mapa de vulnerabilidade dos solos no semiárido de Pernambuco.

Seguindo o estudo de [27], foram classificadas as cartas em três classes que retratam as áreas moderadamente degradadas ou de risco médio, áreas degradadas ou de alto risco e áreas gravemente degradadas ou de risco muito alto. As áreas de susceptibilidade foram mapeadas através da leitura do valor dos pixels, onde na imagem negativo, os valores de níveis de cinza entre 0 e 128 foram classificados como áreas de risco muito alto. Os valores de níveis de cinza entre 129 e 191 foram classificados como áreas de risco alto e os valores entre 192 e 255 como áreas moderadamente degradadas.

A etapa de extração de características com o resultado da geração dos mapas será apresentada no próximo capítulo como resultado que fornecerá a entrada de informações para o simulador.

3.3 *Energy Epidemiology* através da interpretação de Modelos Compartimentais

A modelagem epidemiológica se destaca como uma importante ferramenta de estudo e análise de epidemias [59]. Seus modelos têm contribuído bastante na sugestão de tipos de dados que devem ser coletados, na identificação de tendências e na realização de predições[53]. A

modelagem epidemiológica também vem sendo bastante utilizada no estudo de mídias sociais [117, 61] e de difusão de tecnologias [47, 55].

Há um estudo do efeito epidêmico em conjunto com o efeito rentabilidade na difusão da energia renovável em [68]. O autor utiliza conceitos de um modelo de difusão tecnológica para construir um modelo e aplica sobre a difusão da energia eólica na China.

Uma nova abordagem denominada de *Energy Epidemiology* é proposta pelo Instituto de Energia do Reino Unido (*Energy Institute UCL*), através do RCUK (*Research Councils UK*)⁴. Esta abordagem deu origem ao Conselho de Pesquisa do Reino Unido para a *Energy Epidemiology* (CEE) e é apresentada em [50].

O foco da CEE destina-se a melhor compreensão da utilização final da demanda de energia entre a população e em todo o parque imobiliário. Trata do estudo da demanda energética final, fundada sobre um quadro de pesquisa interdisciplinar em epidemiologia nas ciências da saúde. Esta interdisciplinaridade se dá pela interação e colaboração de várias disciplinas trabalhando em conjunto em um problema, com o objetivo de integrar e sintetizar as teorias técnicas [21, 25].

Segundo [50], a adaptação da abordagem epidemiológica a estudos da utilização final de demanda energética irá fornecer os meios para observar e descrever as tendências e padrões de demanda de energia. A *Energy Epidemiology* irá estabelecer fortes associações entre os fatores que levam a um resultado ou evento de uma demanda de energia. Tal abordagem irá reforçar a base de evidências para informar as decisões políticas e avaliar programas de intervenção passadas ou ações regulatórias.

As subseções a seguir apresentam dois modelos epidemiológicos compartimentais. O primeiro, com baseado na abordagem *Epidemiology Energy* do RCUK. O segundo modelo aborda o processo de distribuição de energia com uma visão epidemiológica.

3.3.1 Modelo SIRS para crescimento de demandas

Nesta subseção será proposto um modelo epidemiológico compartimental para descrever a dinâmica de uma população sujeita a crescimento de demanda. O modelo SIRS divide a população em três compartimentos. Cada compartimento é composto por indivíduos Sus-

⁴Uma visão geral do RCUK está disponível em: <http://www.rcuk.ac.uk/>

ceptíveis (S), Infectados (I) e Recuperados (R).

No modelo proposto, a população pode ser interpretada em diferentes escalas como por exemplo, pessoas físicas, casas, indústrias, edifícios, ou até mesmo, *clusters* desses indivíduos. O primeiro compartimento é o dos indivíduos susceptíveis, ou seja, aqueles que ainda não foram contaminados ou que não estão apresentando crescimento em sua demanda. A segunda classe pertence aos indivíduos infectados, que no caso, são aqueles que estão apresentando algum crescimento na demanda. Por último, temos os indivíduos recuperados. No compartimento *R* estão contidos os indivíduos que já foram susceptíveis, apresentaram um crescimento de demanda, mas se estabilizaram depois de um determinado período de crescimento.

O fluxo de transmissão é ilustrado pela Figura 3.4, onde a transmissão é da classe S à classe I, depois para a classe R e, por fim, de volta a classe S.




Figura 3.4: Fluxograma do modelo compartimental SIRS.

Para o modelo epidemiológico do crescimento de demanda, é considerada uma população de tamanho constante representada por N . No entanto, há a possibilidade de que novos indivíduos susceptíveis passem a compor a população. Para manter o número de indivíduos global constante, é considerado no modelo que o número de novos indivíduos que passam a compor a população (nascimentos) é igual aqueles que deixam de fazer parte desta (mortalidade). Também é importante ressaltar que em modelos compartimentais não existem espaços discretos, assim, os indivíduos podem estar em qualquer lugar a qualquer momento [86].

A totalidade de unidades no tempo t é dado por:

$$N(t) = S(t) + I(t) + R(t),$$

onde $S(t)$, $I(t)$ e $R(t)$ são o número de indivíduos susceptíveis, infectados e recuperados no tempo t , respectivamente.

A transição entre compartimentos se dá sempre pela ordem da Figura 3.4. Temos que $\frac{dS}{dt}$ = taxa de variação de indivíduos susceptíveis, $\frac{dI}{dt}$ = taxa de variação de indivíduos infectados e $\frac{dR}{dt}$ = taxa de variação de indivíduos recuperados, todas no tempo t .

Considerando as hipóteses que seguem:

- (i) A taxa de variação da população susceptível é proporcional ao número de contatos entre as populações susceptível e infectada.
- (ii) A taxa de variação da população recuperada é proporcional à população infectada e a taxa que regula a perda de estabilidade média dos indivíduos recuperados.

Pelas hipóteses levantadas e assumindo que a taxa de infecção é βSI , o modelo SIRS pode ser descrito utilizando as seguintes equações diferenciais ordinárias:

$$\frac{dS}{dt} = -\beta SI + \mu(N - S) + fR,$$

$$\frac{dI}{dt} = \beta SI - \gamma I - \mu I,$$

$$\frac{dR}{dt} = \gamma I - \mu R - fR.$$

em que β é a constante que calibra a taxa de infecção, f é a taxa per capita em que as unidades com crescimento de demanda estabilizados voltam a se tornar susceptíveis, μ é constante e representa a taxa de novos indivíduos que passaram a compor a população e γ denota a proporção de pessoas que deixaram a classe dos infectados, I , para classe dos removidos, R devido a ter estabilizado o crescimento de sua demanda.

Como a população N é constante, temos que:

$$\frac{dS}{dt} + \frac{dI}{dt} + \frac{dR}{dt} = 0.$$

A proposta deste modelo pretende estudar a variabilidade do crescimento de demanda de carga por uma determinada população. Este modelo será combinado a estrutura de um

autômato celular para que seja obtida a heterogeneidade da distribuição dos indivíduos. As equações do modelo SIRS foram conservadas, logo as propriedades matemáticas estão mantidas.

3.3.2 Modelo SIS para distribuição energética

Esta subseção toma como base o modelo epidemiológico compartimental SIS para propor um modelo que descreva o processo de distribuição de energia.

O modelo é composto pelos compartimentos dos indivíduos Suscetíveis (S) e Infectados (I). A classe dos Suscetíveis representa os indivíduos que possuem demanda caracterizada, enquanto os Infectados aqueles passíveis de ter uma demanda.

Neste sentido, a classe dos Suscetíveis deverá incluir todos os indivíduos que possuem demanda de carga de energia no momento. Quando o indivíduo passa a compor o compartimento dos Infectados, este tem sua demanda atendida e pode tornar-se capaz de distribuir carga a outros indivíduos, de maneira análoga a transmissão de uma doença. Caso a quantidade de carga do indivíduo passe a não satisfazer sua demanda, este voltará a classe de suscetíveis.

Assim como o modelo apresentado anteriormente, a população pode ser interpretada em diferentes escalas. A população inicialmente infectada reflete indivíduos próximos a subestações de distribuição. E a infecção de novos indivíduos se dá pelo contato dos mesmos com outros indivíduos suscetíveis através da rede de distribuição. O sistema deverá convergir quando em um tempo t toda a população esteja infectada, logo toda demanda de distribuição terá sido atendida.

O fluxo de transição dos indivíduos nos compartimentos é dado da classe S à classe I, e de volta a classe S, conforme ilustra a Figura 3.5.




Figura 3.5: Fluxograma do modelo compartimental SIS.

A dinâmica do sistema é descrita pelo seguinte sistema de equações diferenciais:

$$\frac{dS}{dt} = -\beta SI + \gamma I,$$

$$\frac{dI}{dt} = \beta SI - \gamma I,$$

onde β é a constante que calibra a velocidade da transmissão e γ regula a proporção de pessoas que deixam a classes dos Infectados. Ambas as constantes são positivas, logo $\beta, \gamma > 0$. Como esse modelo tem por finalidade a visualização do processo de distribuição de energia, não serão considerados novos surgimentos de pontos oferta e de demanda.

A população total N é constante, composta pela soma de todos os indivíduos dos dois compartimentos, logo $N = S + I$ e $\frac{dS}{dt} + \frac{dI}{dt} = 0$.

O objetivo desse modelo é proporcionar uma análise sobre uma perspectiva diferenciada do processo de distribuição, abstraindo atributos técnicos das redes e que auxilie no apoio a decisões gerenciais do processo de distribuição de energia. A heterogeneidade da distribuição dos indivíduos do modelo e a modelagem das transições do autômato que irão ser executadas a partir deste serão definidas na próxima seção. É esperado que a aplicação do modelo a estrutura celular possa possibilitar simulações de possíveis cenários que identifiquem a necessidade da expansão de redes de distribuição.

3.4 Simulador baseado em Autômatos Celulares

Esta seção tem por finalidade a modelagem do simulador computacional, baseado em autômatos celulares e composto pelas dimensões construídas nas seções anteriores.

O objetivo do simulador é analisar cenários de alterações das condições de um diagrama de escalonamento de recursos de energia de forma robusta e que compreenda os processos de geração, transmissão e distribuição de energia, além de auxiliar na tomada de decisão a respeito da expansão da matriz energética.

3.4.1 Dimensões de leitura de informações

Pela dimensão do modelo de otimização será fornecida ao simulador a configuração do despacho ótimo das usinas térmicas. Esta dimensão deverá fornecer o resultado das simulações em uma estrutura matricial com cada célula contendo atributos que forneça localização geográfica, geração das usinas e da carga transmitida aos pontos de demanda, em períodos de tempo com variação horária. Esta dimensão fornece a matriz com a configuração ótima dos recursos para atendimento da demanda.

A dimensões que utilizam informações ambientais deverão fornecer também como entrada, e em formato matricial, informações relativas a geolocalização da área representada em cada célula e o estado assumido pela região em relação ao problema ambiental. Por exemplo, nessa dissertação são gerados mapas autonavegáveis e geolocalizados de regiões classificadas por níveis de susceptibilidade ao processo de desertificação. O simulador terá acesso às áreas que compreendem o estudo e cada célula trará informações quanto a classificação dos solos por nível de susceptibilidade.

3.4.2 Dimensões baseadas em modelos epidemiológicos compartimentais

Esta subseção tem por finalidade apresentar as transições dos autômatos celulares de forma a promover a heterogeneidade das dimensões baseadas em modelos epidemiológicos compartimentais para previsão de demanda e distribuição de energia.

Previsão de crescimento de demanda

A proposta do modelo epidemiológico *SIRS* para previsão de crescimento de demanda apresentado na Seção 3.3.1 tem por objetivo estudar a variabilidade do crescimento de demanda de carga por uma determinada população e tentar prever possíveis cenários futuros.

Como é característico dos modelos compartimentais, o modelo construído trata os indivíduos de maneira espacial e temporalmente homogênea [53]. Para obter a heterogeneidade do sistema, proporcionando a visualização do comportamento individual dos indivíduos, o modelo é discretizados em tempo e espaço através da estrutura do autômato celular.

As transições entre os compartimentos $S \rightarrow I \rightarrow R$ foram construídas considerando as seguintes proposições:

1. Todos os indivíduos pertencentes ao compartimento S têm uma probabilidade $P_i(vI) = \frac{\beta * vI}{v}$, onde β é a taxa de contato definida no modelo epidemiológico, v representa o número total de vizinhos da célula i e vI é o total de vizinhos infectados;
2. O número de indivíduos que passa do compartimento S para o compartimento I é definido pelo resultado da equação diferencial ordinária $\frac{dS}{dt}$. Assim, a transição se dá pelos $\frac{dS}{dt}$ elementos susceptíveis que possuem o maior valor $P_i(vI)$;
3. A transição dos indivíduos da classe I para classe R se dá pelo número $\frac{dI}{dt}$ de indivíduos infectados escolhidos aleatoriamente;
4. A transição dos indivíduos da classe R para classe S se dá pelo número $\frac{dR}{dt}$ de indivíduos recuperados escolhidos aleatoriamente;
5. Para cada indivíduo que deixa de fazer parte do sistema a uma taxa μ , um novo indivíduo susceptível nasce em seu lugar. Portanto, a população permanece constante.

Distribuição de energia

A proposta do modelo epidemiológico SIS para o processo de distribuição de energia tem como objetivo a simplificação da visão do processo de distribuição energética na visão do gestor. Compete a essa dimensão fornecer cenários de distribuição e prever possíveis locais onde a demanda pode não vir a ser atendida, abstraindo dados técnicos relativos a distribuição e promovendo a dinâmica geral do sistema.

As transições entre os compartimentos $S \rightarrow I$ foram construídas considerando os seguintes itens:

1. As taxas $\frac{dS}{dt}$ e $\frac{dI}{dt}$ definem o número de indivíduos susceptíveis que passam a compor a classe de infectados e a quantidade de indivíduos infectados que passam a ser susceptíveis, respectivamente;
2. Os indivíduos definidos a partir da taxa $\frac{dI}{dt}$ são escolhidos aleatoriamente e a energia excedente a sua demanda é distribuída para os vizinhos susceptíveis;

3. A distribuição é realizada proporcionalmente à quantidade de energia demandada por cada vizinho.

3.4.3 Algoritmo geral do simulador

A resolução temporal do simulador é composta por períodos de tempo que podem ser horários, uma vez que a configuração do despacho ótimo das usinas é passada em intervalos de 1 hora.

A Figura 3.6 ilustra o esquema do processo de modelagem do Autômato Celular em termos das suas dimensões. A cada geração ou espaço de tempo do autômato, o estado futuro do simulador, representado pela camada superior, é obtido a partir das leituras das dimensões de entrada e do processamento das dimensões baseadas nos modelos epidemiológicos compartimentais.




Figura 3.6: Modelagem do autômato celular para o gerenciamento de recursos de energia. Adaptado de: [2].

Cada dimensão representada pelas matrizes inferiores contém atributos característicos do estado da célula na dimensão. Para as dimensões de leitura, temos a configuração do despacho das usinas térmicas e os níveis de susceptibilidade dos solos ao processo de desertificação. Para as dimensões baseadas em modelos epidemiológicos compartimentais, temos a previsão do crescimento da demanda da região e seu atendimento através do processo de distribuição de energia.

O algoritmo da simulação é descrito pelos seguintes passos:

Algorithm 2 Algoritmo de execução do simulador

- 1: Execute a dimensão do modelo de otimização para despacho das usinas térmicas e leia as informações.
 - 2: Para cada célula, execute a distribuição da carga através da dimensão de distribuição.
 - 3: Todas as células foram atendidas? Se não, PARE! Forneça possíveis locais para expansão da matriz baseado nas dimensões ambientais. Se sim, CONTINUE.
 - 4: Simule casos de crescimento de demanda através da dimensão de previsão de crescimento de demanda.
 - 5: Atualize os valores de demanda.
 - 6: Repita o algoritmo para o tempo $t+1$.
-

Capítulo 4

Resultados

Neste capítulo serão apresentados e discutidos os resultados obtidos na pesquisa. Os experimentos foram realizados em cada uma das quatro dimensões construídas e os resultados serão apresentados nas seções a seguir.

4.1 Dimensão de otimização do despacho de usinas térmicas para o Sistema Interligado Nacional

As simulações da dimensão de otimização do despacho de usinas térmicas foram realizadas através da resolução do modelo de otimização construído na Seção 3.1 e simulado com dados reais da operação do dia 10/11/2015 do Sistema Interligado Nacional. O SIN é formado pelos geradores, transmissores e distribuidores das regiões Sul, Sudeste, Centro-Oeste, Nordeste e parte da região Norte. Estas regiões são agrupadas em quatro subsistemas conforme ilustrado anteriormente na Figura 3.2, o subsistema Norte (N), Nordeste (NE), Sul (S) e Sudeste/Centro-Oeste (SE/CO). Segundo o ONS, apenas 1,7% da energia requerida pelo país não está conectada ao SIN, encontrando-se em pequenos sistemas isolados localizados principalmente na região amazônica. Os resultados dessa dimensão produzem a configuração ótima do acionamento das usinas térmicas e o balanço de cargas por intercâmbios para atendimento da demanda dos subsistemas.

Os experimentos foram realizados com auxílio da plataforma AIMMS versão e *release* 4.13.4.280 de 64-bits, sob licença educacional *Stand-Alone*. Utilizou-se o *solver* CPLEX

12.6.2. Entre algumas características da plataforma AIMMS estão a integração do CPLEX e a facilidade de integração dos procedimentos com linguagens de programação e ferramentas de interface com bases de dados[56]. Este item é de fundamental importância para integração dos resultados do modelo como dimensão de entrada para o simulador baseado em autômatos celulares.

A máquina utilizada durante os experimentos possui processador Intel(R) Core(TM) i7-5500U 2,40GHz, 16GB de memória e um sistema operacional de 64bits. O desempenho da resolução do modelo proposto para o cenário do Sistema Interligado Nacional é resumido na Figura 4.1.

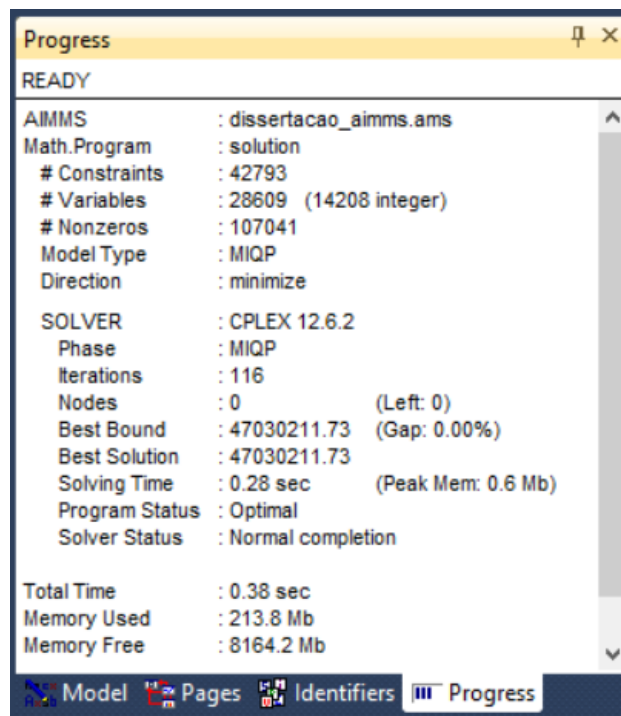


Figura 4.1: Resumo da resolução e simulação da operação do SIN (10/11/2015) pela plataforma AIMMS.

Foram consideradas as 148 usinas térmicas pertencentes aos quatro subsistemas do SIN. O modelo gerou um conjunto de 28.609 variáveis, destas 14.208 inteiras e um conjunto de 42.793 restrições. Foram necessárias 116 iterações, totalizando 0.28 segundos de tempo de resolução. O tempo total da simulação foi de 0.38 segundos com um consumo de 213.8MB de memória.

4.1.1 Levantamento de dados para o modelo de otimização

Para realização dos experimentos foi necessário levantamento de dados junto a Agência Nacional de Energia Elétrica (ANEEL), a Câmara de Comercialização de Energia Elétrica (CCEE) e o ONS.

A ANEEL é a agência reguladora, vinculada ao Ministério de Minas e Energia (MME) e tem por finalidade regular e fiscalizar a produção, transmissão e comercialização de energia elétrica, em conformidade com as políticas e diretrizes do governo federal [49]. Através do seu Banco de Informações de Geração (BIG)¹ foram obtidas informações sobre geração e localização da matriz energética brasileira.

A CCEE divulga periodicamente os "decks de preços" em sua biblioteca pública virtual². Este deck contém informações mensais detalhadas a respeito das diversas fontes geradoras que compõem o SIN e dos seus respectivos subsistemas. Alguns dos arquivos do deck fornecem entradas para parâmetros de outros modelos de otimização, tais como o NEWAVE e o DECOMP. Os parâmetros referentes as usinas térmicas dos subsistemas foram alimentados a partir de dados dos arquivos TERM.DAT e CLAST.DAT, ambos de entrada do modelo NEWAVE e divulgados através do *deck*.

Além dos dados referentes as usinas térmicas obtidos a partir dos arquivos base do NEWAVE, também foram adicionadas outras quinze usinas presentes na operação do dia de estudo de acordo com o Boletim Diário da Operação (BDO)³. Este boletim é um documento disponibilizado diariamente e de forma pública pelo ONS com os resultados da operação do SIN. As térmicas adicionadas foram: BL SOBRINHO, CAMPOS, CELSO FURTADO, GOV.L.BRIZOLA, L.C.PRESTES, MARIO LAGO, ROMULO ALMEIDA, SANTA CRUZ, JE.SO.PEREIRA, U. AURELIANO CHAVES, EUZEBIO ROCHA, ATLANTICO, IPAUSSU, U.PERNAMBUCO e TERMONORTE II. Como não foram obtidos os custos para produção do MWh por essas geradoras, foi considerado como entrada para o modelo os custos médios para geração do MWh de cada subsistema ao qual pertencem as geradoras

¹O Banco de Informações de Geração (BIG) é disponibilizado pela ANEEL através do site: <http://www2.aneel.gov.br/aplicacoes/capacidadebrasil/capacidadebrasil.cfm>.

²O CCEE disponibiliza de forma pública todos os documentos relacionados às atividades e operações da câmara através da sua biblioteca virtual disponibilizada em: http://www.ccee.org.br/portal/faces/aceso_rapido_header_publico_nao_logado/biblioteca_virtual

³O BDO é disponibilizado em: http://www.ons.org.br/resultados_operacao/boletim_diario/.

citadas. Os valores foram $R\$362.22$ para SE/CO, $R\$556.62$ para Nordeste e $R\$489.37$ para o subsistema Norte.

As informações da geração de energia por fontes hidrelétricas e complementares de cada subsistema também foram obtidas pelo Boletim Diário da Operação. Os valores foram disponibilizados em MWh/med . De acordo com o boletim, não houveram importações de carga de outros sistemas na data de estudo.

Devido a indisponibilidade de dados referentes aos custos de intercâmbio entre subsistemas no período de estudo, tomou-se como base o valor adotado em [69], de $R\$5$ por MWh como custo unitário de intercâmbio.

Os dados da variação de demanda de carga dos subsistemas do SIN foram obtidos discretizados por hora através de contato com a Gerência de Previsão e Acompanhamento de Cargas do ONS. Os valores da variação de carga fornecidos pela gerência contam com todas as perdas de intercâmbio e transmissão. Essas perdas ocorrem por diversas naturezas, tais como por dissipação de calor nos condutores e enrolamentos de equipamentos (efeito Joule), pelo ciclo de histerese dos transformadores e reatores, por corrente e fuga e nos isoladores no ar [20]. Devido aos dados obtidos já contarem com a quantidade de carga perdida somada a carga demandada pelos subsistemas, a restrição de perdas por intercâmbios foi desconsiderada na simulação.

A variação da demanda horária de cada subsistema do SIN é ilustrada pelo gráfico da Figura 4.2(a). A demanda média de carga do SIN durante a operação foi de $66.196,36MWh$, com mínima de $53.832,25MWh$ às 5h e pico às 16 horas com uma demanda de $75.978,34MWh$. O subsistema SE/CO que compreende a carga das regiões sudeste e centro-oeste representou uma demanda equivalente a quase 59% de toda a demanda do Sistema Interligado Nacional para o dia de estudo.

Alguns aspectos comportamentais da variação da carga demandada devem ser discutidos. Além de parâmetros como região, população e distribuição demográfica, a demanda de eletricidade também varia de acordo com a estação do ano, dependendo do nível de luminosidade e do clima, por exemplo. A data de estudo refere-se um dia comercial, uma terça-feira com horário de verão.

De acordo com [32] as cargas mais baixas do dia ocorrem durante a madrugada, quando se diminui a utilização de energia elétrica nas residências. Podemos observar a afirmação no

intervalo de tempo entre 1-6 horas através das seis primeiras barras do gráfico da 4.2(a). Durante esse período o patamar de energia do SIN é considerado leve. Os patamares são agregações de carga simplificados em intervalos de horários definidos de acordo com a semelhança entre as características de consumo do SIN [58]. Os patamares são divididos em leve, médio e pesado e variam de acordo com dias comerciais, domingos e feriados onde a atividade comercial/industrial é menos intensa.

O aumento da demanda de carga inicia por volta das 7-8 horas da manhã quando a maioria das pessoas deixam suas residências para ir ao trabalho[32]. A partir das 7 horas o patamar de carga passa a ser médio e dura durante todo o horário comercial/industrial. O comportamento desse patamar pode ser observado entre as barras que representam o período das 7 às 18h quando as atividades comerciais/industriais são mais intensas. Nesta época do ano, devido a estação e as altas temperaturas é comum que o patamar médio seja superior ao pesado que se inicia às 19h. A variação do gráfico entre o período das 12-14 horas refere-se a troca de turno no período comercial/industrial.

Após a queda de demanda observada no intervalo das 17-19h devido ao término do horário comercial/industrial, um novo crescimento ocorre após as 19h devido a entrada da iluminação pública e a utilização de energia nas residências. Este horário marca o patamar de energia pesada e tem duração de aproximadamente 3 horas subsequentes [32] e durante este período oscilações na curva de demanda por eventos culturais, esportivos e sociais são mais frequentes. Em dias de inverno é comum que o pico máximo da demanda seja por volta desse horário, quando o período de energia média tem um valor de carga mais baixo devido ao clima e as temperaturas mais baixas.

Uma síntese dos dados referentes a composição dos parâmetros do modelo é apresentado pela Tabela 4.1. Esta tabela traz os conjuntos e variáveis do modelo e seus respectivos valores ou caminho para a obtenção dados utilizados no experimento.

4.1.2 Resultados da Simulação

Com base nos dados levantados foi realizada a resolução e simulação do modelo de otimização através da plataforma AIMMS para o dia 10/11/2015. A Figura 4.2(b) apresenta o gráfico com a variação da carga de geração térmica adicional obtida através do despacho ótimo das usinas dos subsistemas durante as 24 horas do dia de estudo.


Tabela 4.1: Preenchimento dos parâmetros a partir dos dados coletados.

Sets	Valor
T	24 períodos de tempo
LT, LH e LC	Ver Apêndice A.2.1
S	N, NE, SE/CO e S
Parâmetros	Valores
d_k^t	Ver Apêndice A.2.3
$ot_{i,k}$, $ct_{i,k}$, $gtmin_{i,k}$ e $ftmax_{i,k}$	Ver Apêndice A.2.2
$gh_{l,k}$ e $gc_{m,k}$	Ver Apêndice A.2.2
imp_k	Não houveram importações no período.
cp	As perdas de intercâmbio não foram consideradas.
$cint$	R\$ 5MWh

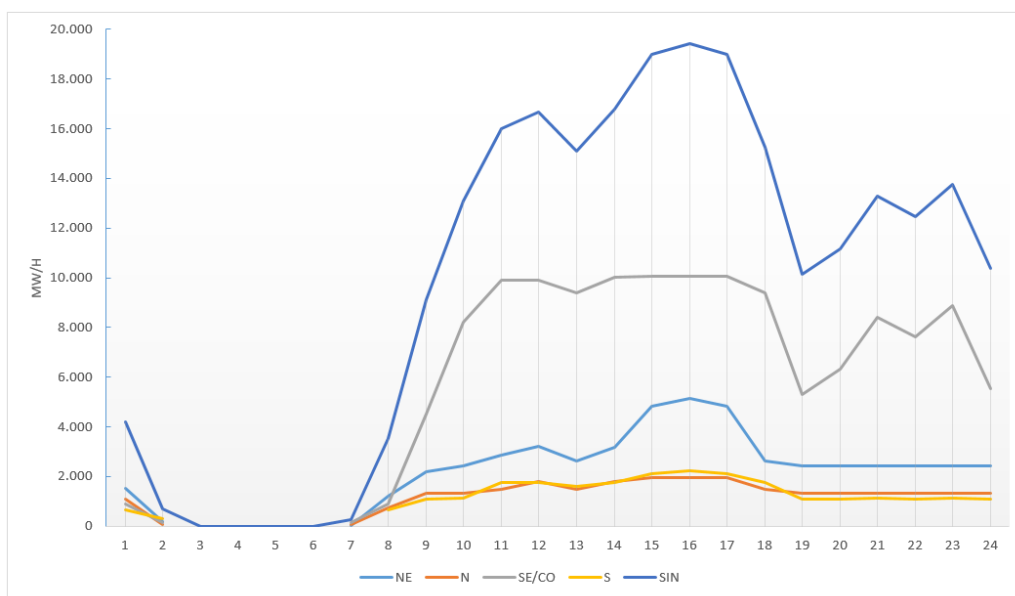
O comportamento da variação da carga de geração térmica adicional é proporcional à variação da demanda apresentada em 4.2(a). As colunas que representam o intervalo de tempo das 3-6 horas indicam que não houve geração de carga adicional nos subsistemas no SIN. Isso ocorre porque o montante de energia hidrelétrica somado a complementar mais a parte inflexível prevista em contrato das geradoras térmicas é maior que a carga de demanda total do sistema. O início do acionamento das térmicas para geração de carga adicional inicia no período das 7-8 horas, quando a demanda do sistema apresenta um crescimento em sua curva devido ao início do horário comercial/industrial. A geração térmica adicional se estende por todo o período do patamar de carga média, havendo uma redução seguida de aumento de carga no horário de troca de turno conforme as barras referentes ao intervalo entre as 12-14 horas.

O pico máximo da geração térmica adicional acontece às 16h, horário em que a demanda do SIN para o dia de estudo tem ponto máximo. A carga adicional gerada nesse período chega a 19.414,61MWh.

O gráfico apresentado pela Figura 4.3 mostra o resultado da variação da geração térmica total do SIN durante os intervalos de tempo do dia 10/11/2015. O montante refere-se a soma da parte inflexível (em azul) e a parte adicional (em laranja) discretizados em função das 24 horas do dia. Conforme observado na análise da Figura 4.2, parte do período de patamar de carga leve (entre 3 e 6h) não foi necessário a geração de carga térmica adicional. Esse



((a))



((b))

Figura 4.2: (a) Variação da demanda horária Demanda horária dos subsistemas do SIN e (b) Resultado da simulação da variação de carga térmica adicional gerada pelos subsistemas do SIN ou fonte de geração para o dia 10/11/2015.

resultado é ilustrado na Figura 4.3 representado pelo gradiente de cor azulada nas barras 3-6 do gráfico. A decisão da utilização dessa parte inflexível é tomada pelo operador do sistema de acordo com os contratos que preveem a inflexibilidade. Uma opção alternativa seria a geração e utilização da parte inflexível provendo a diminuição da geração de carga pelas

usinas hidrelétricas com menor nível de energia armazenada em seus reservatórios durante o período.




Figura 4.3: Resultado do montante da geração térmica (inflexível + adicional) para a operação do dia 10/11/2015.

No gráfico da Figura 4.4 é ilustrado o resultado da geração média para o período, em *MWh* e por tipo de fonte geradora de cada subsistema para a operação da data do estudo. Apenas as regiões Sul e Nordeste possuem fontes de geração complementar interligadas ao SIN. O Nordeste conta com 31,78% da carga gerada pelo subsistema atribuído aos parques eólicos instalados na região, que por sinal é onde concentra-se o maior potencial eólico do país segundo o Banco de Informações da ANEEL. Um outro ponto importante a ser discutido é que embora a região Sudeste estivesse passando por uma crise hídrica e seus reservatórios estivessem em menos de 30% da capacidade, segundo o panorama da Comerc⁴ o subsistema SE/CO que compreende as regiões sudeste e centro-oeste apresentou um percentual de cerca de 75% da sua geração elétrica por fontes hidrelétricas. Parte se justifica pela presença da usina de Itaipu estar conectada a esse subsistema, mesmo situando-se no estado do Paraná. Segundo noticiários locais⁵ Itaipu operou praticamente durante todo o mês de novembro de

⁴Disponível em: <http://www.panoramacomerc.com.br/?p=4333>

⁵Disponível em: <http://g1.globo.com/pr/oeste-sudoeste/noticia/2015/11/apos-quatro-anos-vertedouro-de-itaipu-volta-abrir-todas-comportas.html>

2015 com o vertedouro aberto devido ao excesso de água acumulado em seu reservatório. A produção média segundo o boletim diário da operação na data foi de $10.787 MWh/med$ dos $19.965 MWh/med$ gerados por todo o subsistema hidrelétrico do subsistema.

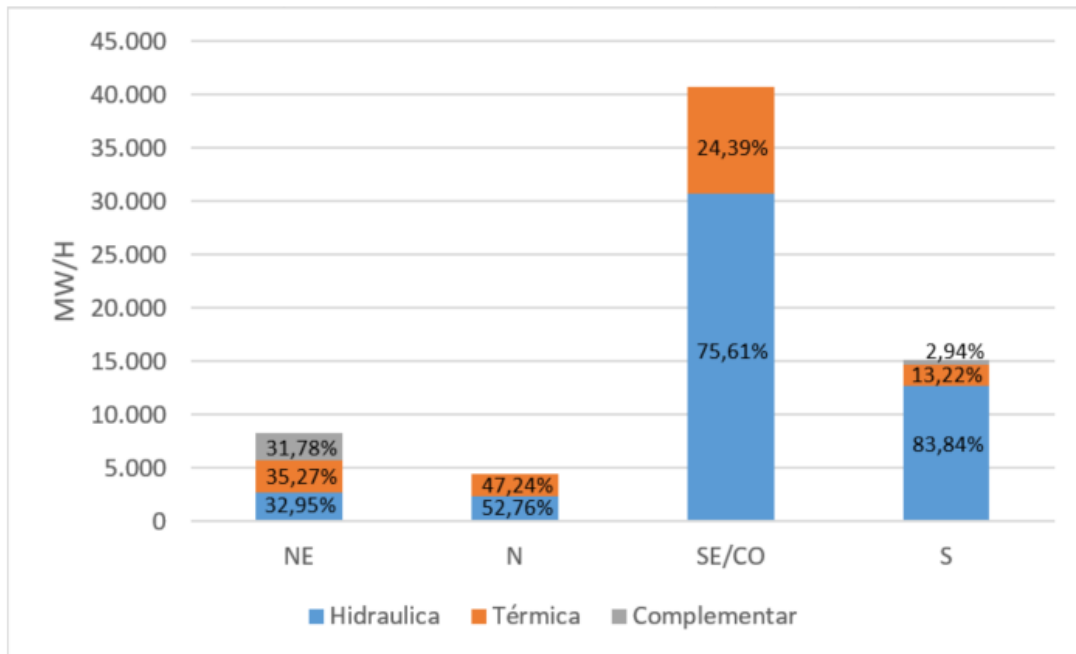


Figura 4.4: Resultado da simulação do SIN por fonte de geração para o dia 10/11/2015.

Os resultados dos intercâmbios entre os subsistemas é ilustrado pela Figura 4.5. Os subsistemas S e SE/CO foram os fornecedores de carga por intercâmbios durante o período conforme ilustrado em 4.5(a). O fornecimento por parte desses subsistemas se justifica por possuírem os menores custos médios para geração de energia adicional no período, $R\$226.03$ para o subsistema S e $R\$362.22$ para SE/CO. Por sua vez, as regiões N e NE mantinham preço médio unitário de $R\$556.62$ e $R\$489.37$ o MWh , respectivamente.

A região Sul foi a que mais forneceu carga por intercâmbio. Durante o novembro de 2015, segundo o panorama da Comerc, esta região contava com seus reservatórios hidrelétricos cheios. Como sua demanda era praticamente atendida pelas fontes hidrelétricas e complementares, toda a energia térmica gerada poderia ser utilizada em intercâmbio. Outro fato interessante que pode ser observado nos gráficos da Figura 4.5(a-b) é que nos períodos entre as 8-9h e as 14-17h o subsistema SE/CO passa do estado de fornecedor de intercâmbio para receptor. Isso ocorre devido ao primeiro intervalo ter uma elevada curva de crescimento da

<http://g1.globo.com/pr/oeste-sudoeste/noticia/2015/11/hidreletrica-de-itaipu-atinge-marca-historica-de-23-bilhoes-de-mwh.html>

demanda no horário quando a demanda geral do sistema ainda não havia atingido um valor tão elevado. Nesse caso, além do crescimento da geração adicional pela região, ainda saiu a um menor custo receber energia por intercâmbio da região Sul. No segundo intervalo, que é quando também ocorre o pico máximo diário 14-17 horas, as usinas térmicas da região SE/CO já estão quase todas despachadas, a região nordeste passa a gerar mais carga adicional, diminuindo sua energia recebida por intercâmbio e a região SE/CO passa a receber parte da carga transmitida pela região Sul.

O pico de fornecimento por intercâmbio ocorre durante o horário leve, conforme mostra as seis primeiras barras do gráfico da figura 4.5(a). Nesse patamar, a demanda do SIN é mais baixa, logo a quantidade de energia térmica adicional consegue ser atendida pelas fontes geradoras com o preço do *MWh* mais baixo. Por isso há uma maior quantidade de intercâmbios.

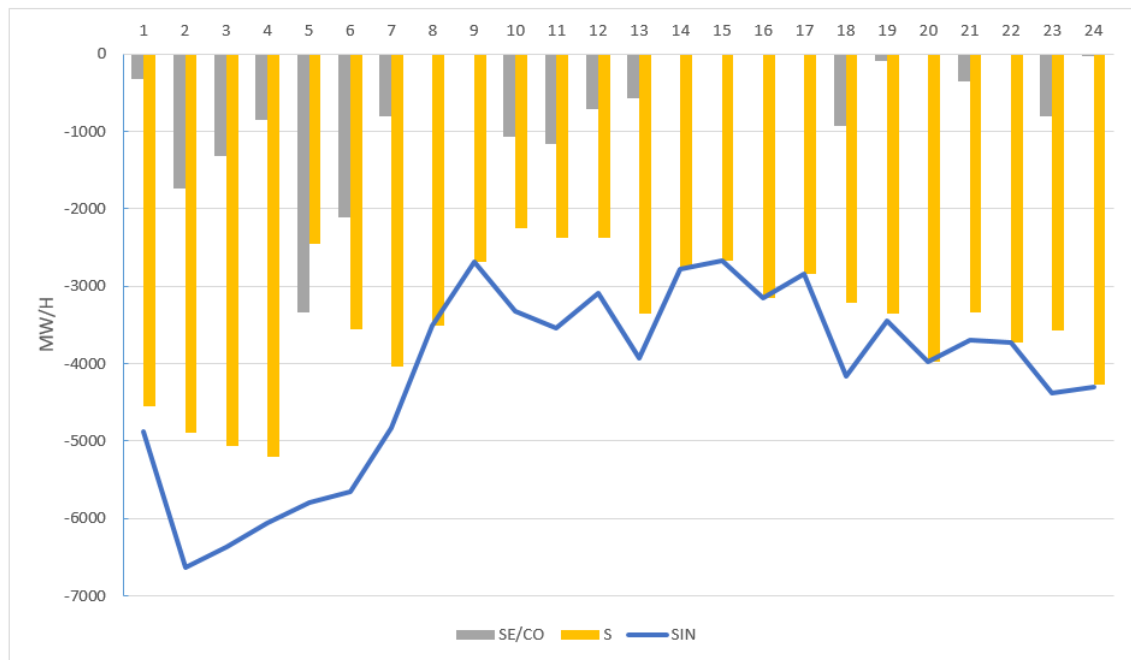
O gráfico de recebimento Figura 4.5(b) é exatamente o oposto do de fornecimento considerando o eixo do SIN. Isso acontece pelo fato de não ter sido consideradas as perdas de intercâmbio, sendo atribuído apenas um custo pelo *MWh* transferido.

As informações da configuração ótima das usinas térmicas despachadas são fornecidas ao simulador no formato de uma matriz. Cada célula armazena informações referentes a localização das geradoras e da quantidade de carga gerada por cada fonte. Assim, por essa dimensão, o simulador terá acesso a configuração da geração de toda a matriz energética do sistema.


4.2 Dimensão de coleta de dados ambientais através de Geoprocessamento e Sensoriamento Remoto

Os experimentos desta etapa da pesquisa foram realizados no Laboratório de Geoprocessamento e Sensoriamento Remoto da UFRPE (GEOSERE). Funcionando desde o final de 2001, o laboratório possui uma estação receptora de imagens, fruto de uma parceria entre a UFRPE e o Centro Aeroespacial Alemão⁶. Os resultados também fazem parte do projeto Desert-MAP, a *software plataforma* e serão publicados posteriormente através do endereço <http://www.spectralmaps.com/desert/>.

⁶Disponível em: <http://www.dlr.de>



((a))



((b))

Figura 4.5: (a) Resultados dos intercâmbios fornecidos entre os subsistemas para operação do dia 10/11/2015. (b) Resultados dos intercâmbios recebidos entre os subsistemas para operação do dia 10/11/2015.

Através da metodologia que utilizou técnicas de Geoprocessamento e Sensoriamento Remoto para geração de mapas por grau de susceptibilidade de solos ao processo de desertificação apresentada na Subseção 3.2, foram gerados mapas autonavegáveis para o Estado de Pernambuco.

As imagens utilizadas foram captadas pelos sensores TM e OLI dos satélites LANDSAT5 e LANDSAT8 nos anos de 2004 e 2015. Foram utilizadas cenas que compreendem o estado pernambucano, com exceção da região litorânea e da Zona da Mata. O motivo da exclusão ocorreu devido as regiões dessas cenas não estarem susceptíveis ao processo em estudo, por serem compostas por mangues e florestas tropicais.

A classificação e extração das características foi realizada com base no valor dos atributos espectrais após a etapa de segmentação que considerou regiões com níveis de até 5 tons de cinza como medida de similaridade. Conforme definido por [27], as regiões que apresentaram na imagem negativo segmentada, valor entre 0 a 128 foram classificadas como áreas de risco muito alto, de 129 a 191 para áreas de risco alto e de 192 a 255 como áreas de risco moderado.

O resultado global dos níveis de susceptibilidade obtidos pela classificação e extração de características das imagens do estado no ano de 2015 é apresentado na Figura 4.6. As áreas com cor vermelha referem-se as gravemente degradadas, logo abrangem áreas onde os solos são altamente susceptíveis à desertificação. A área do mapa em cor amarela representa áreas degradadas que contemplam solos em processo de degradação menos acentuado. Em verde estão as áreas moderadamente degradadas que contemplam solos com baixo nível de degradação. A maior concentração de se dá no núcleo de desertificação de Cabrobó (PE). A cidade de Cabrobó é marcada na figura, juntamente com as cidades de Belém de São Francisco e Floresta, pertencentes ao núcleo e que possuem os cenários mais críticos do processo. Esta região é composta por Luvisolos, Planossolos, Neossolos e estão continuamente sob fortes processos de degradação [28, 94].

Uma análise temporal da evolução do processo na cidade de Floresta é apresentada na Figura 4.7. Situada no núcleo de desertificação de Cabrobó (PE), Floresta é delimitada de acordo com o polígono apresnetado na Figura 4.7(a). Esta imagem foi apresentada a partir de cenas do sensor TM/LANDSAT5 referentes ao período entre os anos de 1976 e 2008 [28, 27]. Na imagem negativo da cidade os altos valores de níveis de tons de cinza indicam regiões altamente susceptíveis ao processo de desertificação na região. A classificação gerada nesse trabalho e apresentada em 4.7(b) confirma os níveis de degradação a partir de




Figura 4.6: Mapa de níveis de susceptibilidade do solo ao processo de desertificação de Pernambuco para o ano de 2015.

cena do mesmo sensor TM/LANDSAT5 no ano de 2004. A evolução temporal do nível de degradação é bastante significativo, conforme ilustrado em 4.7(c), através de cena obtida pelo sensor OLI/LANDSAT8 no ano de 2015. De acordo com [8] a área ilustrada é considerada muito degradada e em contínuo processo de desertificação. Seus solos são bastante rasos e pedregosos ficando susceptíveis a processos erosivos mais severos.

Os mapas gerados são uteis para identificação de regiões por níveis de degradação do solo, auxiliando na prevenção e combate ao processo de desertificação. Em matrizes energéticas, é esperado que os mapas influenciem na redução de custos e impactos ambientais na etapa de planejamento da expansão da geração e transmissão das matrizes. A ideia dessa dimensão no trabalho é de que outras dimensões ambientais possam ser construídas de forma escalável e que venham fornecer informações ambientais como entrada para o simulador. A combinação dessas informações auxiliará na sugestão de locais que minimizem os prejuízos ambientais, afetando também o planejamento econômico.

A Figura 4.8 exemplifica a leitura do simulador referente a parte do mapa gerado no ano de 2015 pela dimensão de susceptibilidade dos solos ao processo de desertificação. Esta figura reflete parte do núcleo de desertificação de Cabrobó (PE) e compreende os municípios de Belém de São Francisco e Floresta. Cada célula do autômato da Figura 4.8 (b) descreve o estado do grau de susceptibilidade do solo predominante em uma área de $0.3ha$ ou $3.000m^2$.

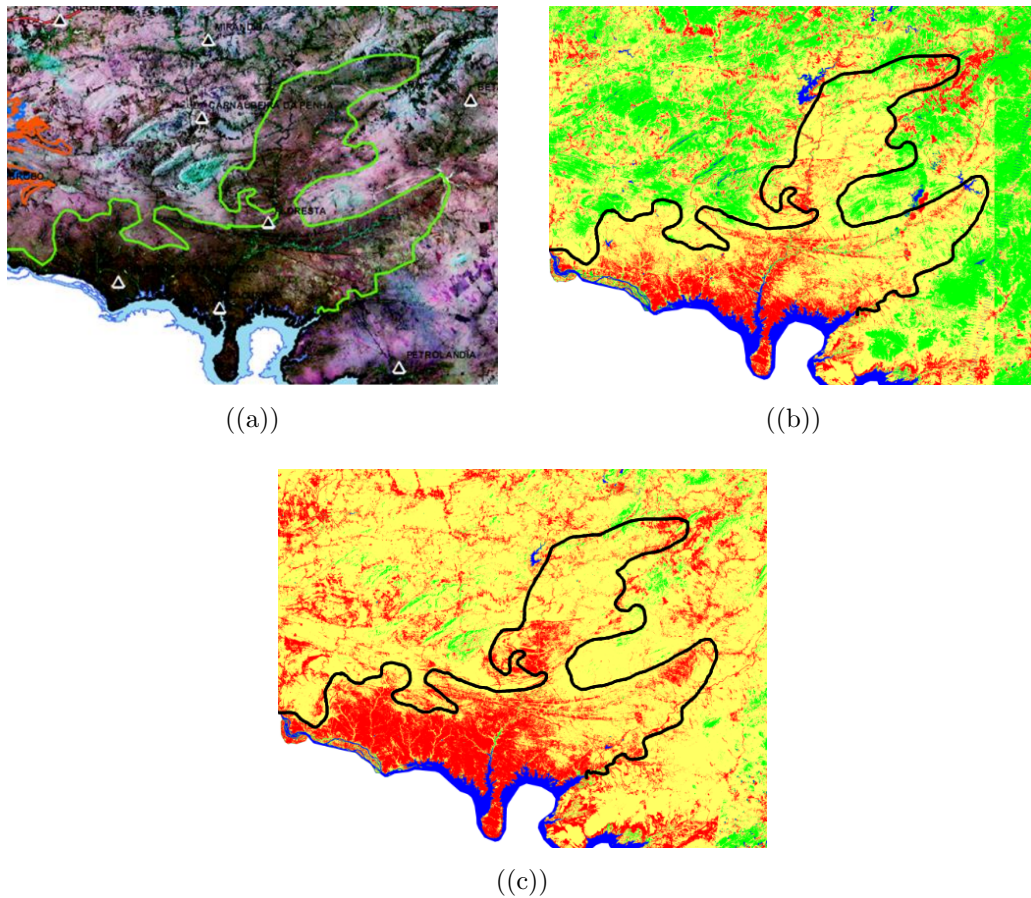



Figura 4.7: Níveis de degradação do solo no Município de Floresta (PE) em (a) 1976-2008 (b) 2004 e (c) 2015.


4.3 Dimensões baseadas em Modelos Matemáticos Epidemiológicos Compartmentais

Os dados da área de estudo dos experimentos foram obtidos através da Gerência do Departamento de Mercado do Grupo Neoenergia. O grupo efetua distribuição de energia para 186 municípios, entre os 185 pernambucanos, incluindo o arquipélago de Fernando de Noronha e o município de Pedras de Fogo situado do estado da Paraíba. As planilhas trazem valores de demanda de carga dos municípios entre 2013 a 2015 e podem ser consultadas através do Apêndice A.3.

Os cenários foram gerados através de um espaço celular composto por uma matriz bidimensional de 22 linhas e 13 colunas (22x13), com um poder de representatividade de 286 células. Cada indivíduo compõe uma célula do autômato e representa um dos municípios atendidos



((a))



((b))

Figura 4.8: Representação do núcleo de desertificação de Cabrobó através do (a) mapa de risco e (b) dimensão de entrada para o simulador.

pelo grupo Neoenergia.

A utilização de uma matriz bidimensional com poder de representatividade maior que o número de municípios atendidos se fez necessário pelo fato dos municípios estarem distribuídos demograficamente. Como a estrutura do autômato celular considera a definição do próximo estado do indivíduo a partir da resposta do seu estado atual e dos estados atuais dos seus vizinhos[67, 100], esta distribuição foi necessária. O resultado do mapeamento demográfico dos municípios no espaço celular pode ser consultado no Apêndice A.3.2. A vizinhança adotada nas simulações foi a de Moore de grau um e limite do espaço é fixo.

4.3.1 Dimensão de previsão de crescimento de demanda

Os valores de classificação dos compartimentos da população inicial foram definidos a partir de análise empírica dos dados fornecidos pelo grupo Neoenergia. O ano base para o estado

inicial foi o ano de 2013. A condição inicial do compartimento dos infectados apresentou 59 municípios considerados em demanda crescente, o equivalente a parcela de 31.72% da população. A população susceptível inicial foi de 127 municípios o que equivale a 68.28% da população total $N = 186$.

As condições iniciais da simulação foram: $S(0) = 127$, $I(0) = 59$ e $R(0) = 0$. A condição $S(0)$ corresponde ao número de indivíduos susceptíveis no estado inicial, $I(0)$ e $R(0)$ os números de infectados e recuperados, respectivamente. Sendo $S(0) + I(0) + R(0) = N$, onde N é a população total que compõe o estado inicial da simulação.

O modelo epidemiológico SIRS para crescimento de demanda foi simulado com a taxa de contato $\beta = 0.0075$, $\gamma = 0.3$, $\mu = 0.001$ e $f = 0.07$. Essas taxas foram definidas através da realização de simulações do modelo SIRS, de forma que este atingiu o equilíbrio. O intervalo de tempo considerado de uma iteração e outra foi de 1 anos ($\Delta t = 1$). Este intervalo foi escolhido como forma a minimizar os efeitos sazonais que afetam a procura de energia, tais como clima e temperatura que variam durante as estações do ano.

A Figura 4.9(a), ilustra o estado inicial do autômato celular. Os indivíduos que compõem a classe de susceptíveis, ou seja, aqueles que não apresentam crescimento em sua demanda são representados graficamente pela cor azul marinho. Os indivíduos que apresentam crescimento de demanda (infectados) estão na cor azul claro. As células na cor vermelha não possuem representatividade. É assumido no estado inicial que não há indivíduos recuperados. Os indivíduos deste compartimento irão surgir ao decorrer das iterações à medida que o crescimento da demanda dos infectados seja estabilizado.

Para classificação inicial dos indivíduos e para definição das transições que realizarão as previsões de demanda, algumas premissas foram definidas (essas premissas foram definidas através da análise empírica do autor sobre os dados coletados junto ao Grupo Neoenergia):

1. Oscilações na demanda dos indivíduos variam em $\pm 5\%$ do valor da demanda.
2. É considerado crescimento de demanda valores entre $+5\%$ e $+10\%$.
3. As oscilações ocorrem nos indivíduos susceptíveis e recuperados.
4. O crescimento da demanda ocorre apenas nos indivíduos infectados.

A Figura 4.9(b)-(f), ilustra a evolução das simulações no período contínuo de 5 anos (2015-




Figura 4.9: Evolução da dimensão de previsão de crescimento de demanda. Em (a) o estado inicial para o ano de 2013. A evolução em (b) 2014, (c) 2015, (d) 2016, (e) 2017, (f) 2018, (g) 2021 e (h) 2026. Em azul marinho, as cidades pertencentes ao compartimento de susceptíveis. Em azul claro, as cidades que apresentam crescimento de demanda (infectadas) e em verde as cidades com crescimento estabilizado (recuperados). As células vermelhas não possuem representatividade.

2018). Os resultados deste intervalo demonstram comportamentos individuais das cidades ao de acordo com o a permutação entre os compartimentos.

Esses cenários podem ser estudados de maneira local ou global através de análise comparativa

com a demanda média da região estudada. No entanto, por se tratar de previsão, é fato que os valores resultantes da simulação não são exatos, mas podem trazer valores bem próximos aos reais quando o modelo adotado está bem calibrado.

Uma vez calibrado, o autômato pode ser usado para gerar cenários de previsão a médio e longo prazo. Para isso, é assumindo que os parâmetros do modelo são mantidos dentro dos intervalos de simulação. Isto significa que não são considerados fatores locais e econômicos que possam acelerar ou desacelerar a o crescimento no período de tempo da simulação.

As previsões para os dois primeiros anos, 2014 e 2015 podem ser comparadas com os dados fornecidos pelo grupo Neoenergia. Ambas as previsões são ilustradas pela Figura 4.10 (a-b). Para 2014 foi prevista uma demanda de $1.102.900 MWh/med$ anual. Para 2015, o valor cresceu para $1.118.400 MWh/med$ anual. Conforme mostra a figura 4.11, os valores reais foram de $1.103.300 MWh/med$ e $1.118.876 MWh/med$.

(a)	(b)
Previsão para o ano de 2014	Previsão para o ano de 2015
ans =	ans =
1.1029e+06	1.1184e+06
Elapsed time is 0.196993 seconds.	Elapsed time is 0.291078 seconds.
(c)	(d)
Previsão para o ano de 2021	Previsão para o ano de 2026
ans =	ans =
1.2675e+06	1.3463e+06
Elapsed time is 2.264556 seconds.	Elapsed time is 2.756799 seconds.

Figura 4.10: Cenários gerados pela dimensão de previsão de crescimento de demanda para os anos de 2014-2026.

Figura 9(c-d) mostra o cenário de previsão de consumo médio anual para o ano 2021 e 2026, respectivamente. É esperado atingir uma demanda de $1.267.500 MWmed$ em 5 anos (2021) e $1.346.300 MWmed$ em 10 anos (2016), conforme a indica simulação. Os tempos

	A	B	AM	AN	AO
4					
5	Nº	MUNICÍPIO	Media 2013	Media 2014	Media 2015
194		TOTAL	1.057.848	1.103.300	1.118.876

Figura 4.11: Demanda média anual de carga distribuída pelo grupo Neoenergia nos período entre 2013 e 2015.

computacionais para realização destas previsões foram de 2.26 e 2.76 segundos.

4.3.2 Dimensão de distribuição de energia

Para a simulação, foram realizadas tentativas de obtenção de dados com granularidade mais baixa, como a representação de uma cidade ou um bairro, por exemplo. Isso traria uma melhor percepção do processo. No entanto, como estes dados não foram obtidos, foi considerado a mesma área de estudo da seção anterior, com uma população $N = 186$. Também não foram obtidos dados das principais estações de distribuição da área de estudo interligadas ao Sistema Interligado Nacional. Por isso, foram criados três pontos de oferta para representar estas estações.

As condições iniciais da simulação foram: $S(0) = 183$ e $I(0) = 3$. A condição $S(0)$ corresponde ao número de indivíduos susceptíveis no estado inicial, ou seja, os que possuem demanda caracterizada. A condição $I(0)$ corresponde aos indivíduos que são passíveis de ter uma demanda, mas que podem no momento distribuir energia. Assim, a população total inicial N é composta por $S(0) + I(0)$.

O modelo epidemiológico SIS para visualização do cenário de distribuição foi simulado com a taxa de contato $\beta = 0.004$ e $\gamma = 0.01$. O intervalo de tempo considerado de uma iteração assume um valor próximo de zero, pois simboliza o intervalo de transferência de carga pela infraestrutura da distribuição.

A Figura 4.12 mostra a variabilidade da transmissão a partir da permutação dos indivíduos entre os compartimentos $S \rightarrow I$. Observa-se que o número de infectados cresce até atingir um número máximo de indivíduos próximo ao número total da população, e em seguida estabiliza-se lentamente tendendo a infecção de todos os indivíduos.

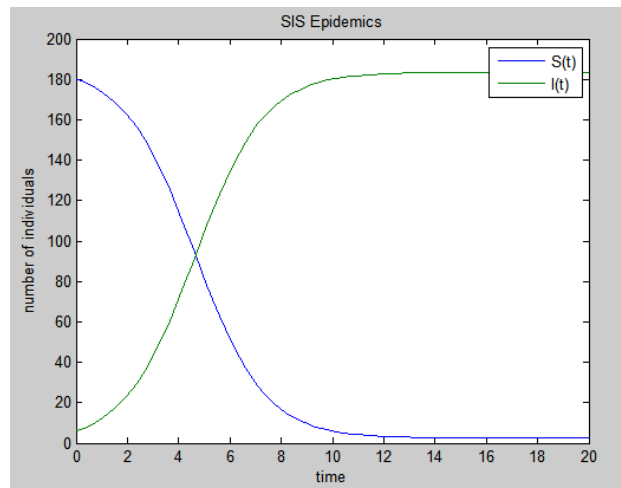


Figura 4.12: Variação dos indivíduos Suscetíveis e Infectados durante a simulação do modelo SIS de distribuição de energia.

O cenário dos indivíduos distribuídos heterogeneamente na estrutura de um autômato celular é apresentado na Figura 4.13. Ele fornece a visualização da dinâmica do espalhamento dos recursos, no sentido de que é possível visualizar o atendimento dos indivíduos que possuem demanda a cada instante de tempo (iteração).

O cenário da Figura 4.13 (a-c) mostra a velocidade (iterações) dessa dinâmica de acordo com as curvas visualizadas pelo gráfico da Figura 4.11. Ao final, o processo dura um número mais prolongado de iterações, pois os recursos já estão praticamente esgotados. Um outro aspecto interessante a ser discutido é a cidade do Recife, representada pela célula marcada em (h). Mesmo próximo a duas estações de distribuição, esta demora várias iterações para que tenha sua demanda atendida devido à alta quantidade de carga demandada, que corresponde a mais de 26% da demanda de todo o estado.

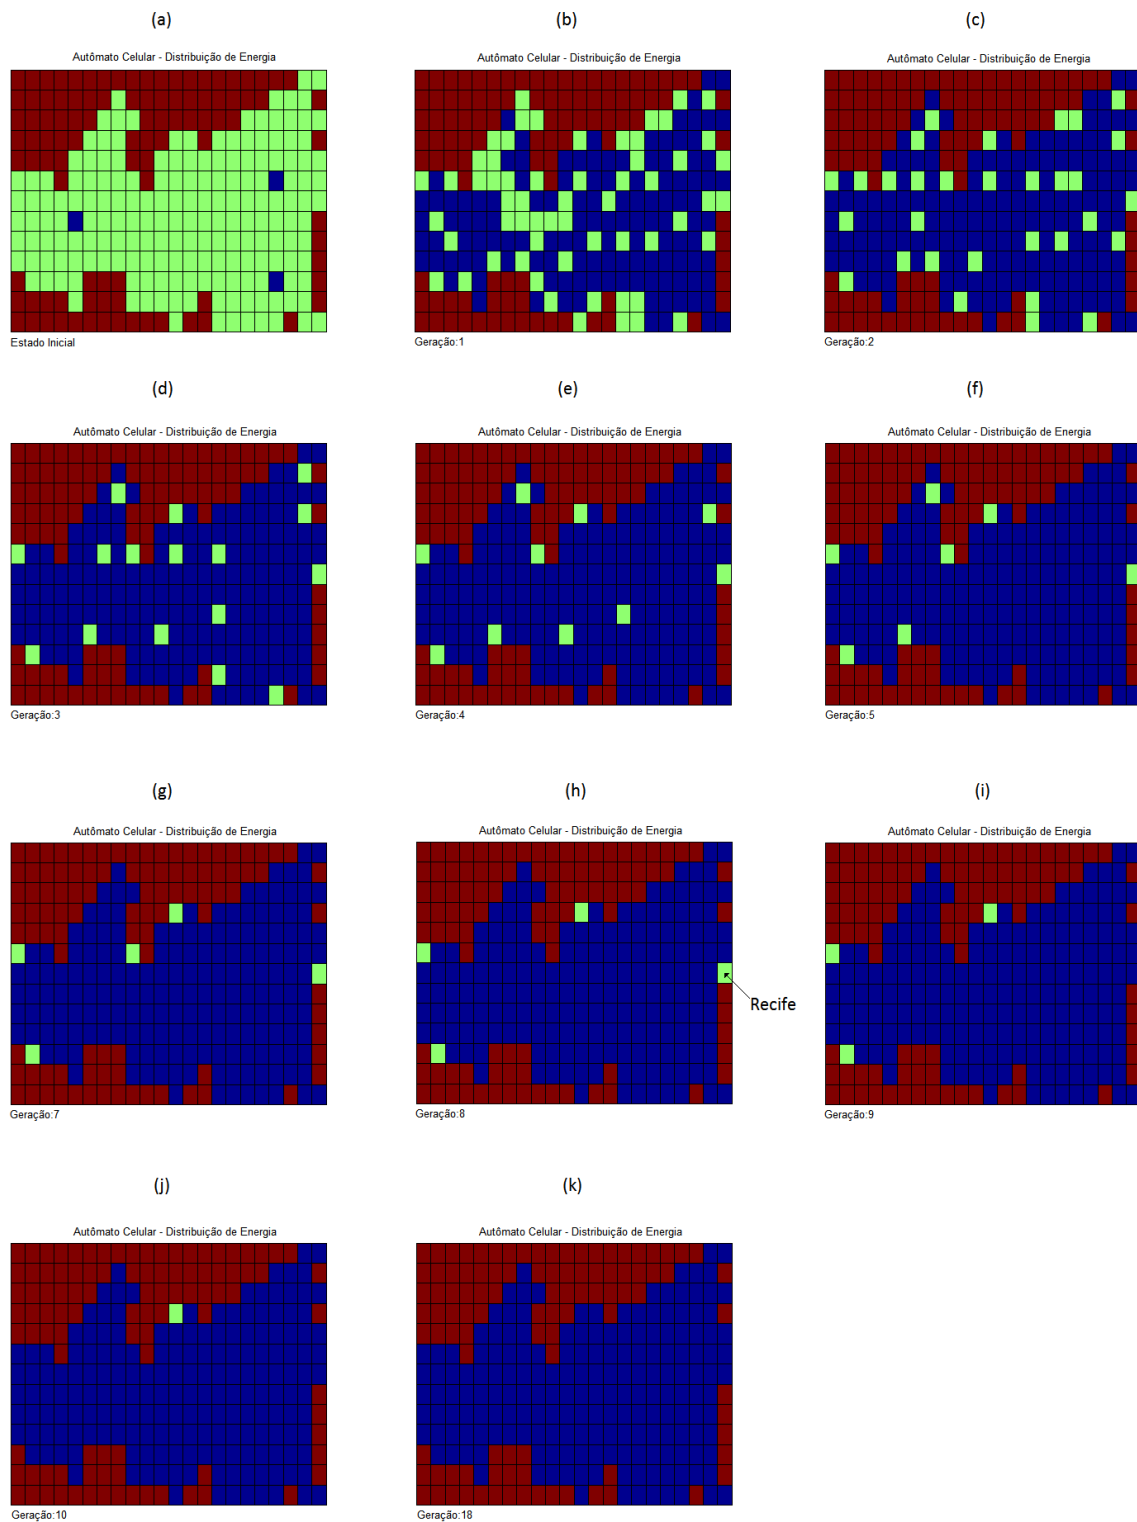


Figura 4.13: Simulação da visualização do processo de distribuição de energia por um autômato celular.

Capítulo 5

Conclusões e Trabalhos Futuros

Nesta dissertação foi apresentada uma proposta baseada em autômatos celulares, para auxiliar no gerenciamento de matrizes energéticas. Para isso foi utilizado um modelo de captura de dados geoespaciais por satélite que foi chamado de Desert-MAP, um modelo de otimização baseado em programação linear inteira mista e modelos compartimentais para caracterização de demanda. Os resultados parciais de cada uma das quatro dimensões foram obtidos com dados fornecidos por parceiros e por pesquisa web aos órgãos do setor elétrico. Entretanto, para simular o sistema unificado pelas 4 dimensões é necessária uma massa de dados unificada e por isso esta simulação foi deixada como trabalhos futuros

Neste trabalho contribuiu-se de acordo com os objetivos com a criação de uma metodologia para geração automática de mapas autonavegáveis para obtenção de parâmetros ambientais. Os mapas aqui gerados medem o nível de susceptibilidade de solos ao processo de desertificação para o estado de Pernambuco e são escaláveis, portanto a metodologia pode ser aplicada a qualquer região.

Através da Modelagem Matemática de Otimização, utilizando PLIM, foi criado um modelo de otimização para a operação diária do despacho ótimo de usinas térmicas. O modelo foi resolvido e simulado com dados reais do Sistema Interligado Nacional obtendo resultados da configuração ótima do sistema para o dia da operação.

Através da utilização de Modelos Epidemiológicos Compartimentais, do conceito de *Energy Epidemiology*, e da estrutura de um autômato celular, foram geradas previsões de demanda de carga para as cidades atendidas pelo grupo Neoenergia. Assim como também foram

simulados cenários de distribuição de energia na visão de um Autômato Celular. Para serem aplicados em outras localizações específicas, esses modelos devem ser recalibrados, assim como as funções de transição, para que possa impedir cenários irrealistas.

5.1 Trabalhos Futuros

A caráter de suprir as limitações deste trabalho, sugerimos como trabalhos futuros:

- (i) A tentativa de avaliação de campo em algumas das áreas degradadas indicadas no mapa.
- (ii) A criação de outros mapas para geração de produtos para *-MAP e não apenas DESERTMAP, através de estudos de outros fatores ambientais para geração de metodologias além da gerada para desertos, tais como urbanização, desmatamento, águas e vegetação.
- (iii) Adicionar fatores de perdas de transmissão ao modelo matemático de otimização assim como restrições de intercâmbios.
- (iv) A inserção de restrições de perdas de distribuição nas transições do autômato calcular da dimensão descrita pelo modelo epidemiológico SIS.
- (v) Avaliação estatística dos parâmetros que compõem os modelos epidemiológicos utilizados.
- (vi) Avaliação das previsões de crescimento de demanda.
- (vii) A continuação da busca de dados através da tentativa de parcerias para realização da simulação unindo todas as dimensões construídas.
- (viii) Término da confecção dos artigos relativos a pesquisa e submissão a revistas bem qualificadas.

Referências Bibliográficas

- [1] AIMMS. Disponível em <<http://www.aimms.com/>>. Acesso em janeiro de 2016, 2016.
- [2] Jones Oliveira Albuquerque, Silvana Bocanegra, Jordi Ferrer-Savall, Daniel López Cordina, Marco Antônio de Souza, Reinaldo Souza Santos, Constança Barbosa, et al. A two years simulation using a real data cellular automaton: A predictive case study with the schistosomiasis expansion process along the coastline of brazil. 2013.
- [3] Linda JS Allen, Fred Brauer, Pauline Van den Driessche, and Jianhong Wu. *Mathematical epidemiology*. Springer, 2008.
- [4] AMPL. Disponível em <<http://www.ampl.com/>>. Acesso em janeiro de 2016, 2016.
- [5] Reinaldo Gen Ichiro Arakaki and Luiz Antonio Nogueira Lorena. Uma heurística de localização-alocação (hla) para problemas de localização de facilidades. *Revista Produção*, 16(2):319–328, 2006.
- [6] Everardo VSB Araújo, B Araújo Maria do Socorro, and Yony SB Sampaio. Impactos ambientais da agricultura no processo de desertificação no nordeste do brasil. *Revista de Geografia (Recife)*, 22(1):90–112, 2008.
- [7] Pedro Felipe da Silva Araújo. Programação linear e suas aplicações: definição e métodos de soluções. 2013.
- [8] JC Araujo Filho, AB Silva, FBR Silva, and AP Leite. Diagnóstico ambiental do município de floresta, pernambuco. *Embrapa Solos. Circular Técnica*, 2001.
- [9] Udoy S Basak, Bimal Kumar Datta, and Prodip Kumer Ghose. Mathematical analysis of an hiv/aids epidemic model. *American Journal of Mathematics and Statistics*, 5(5):253–258, 2015.

- [10] Brandon T Bestelmeyer, Gregory S Okin, Michael C Duniway, Steven R Archer, Nathan F Sayre, Jebediah C Williamson, and Jeffrey E Herrick. Desertification, land use, and the transformation of global drylands. *Frontiers in Ecology and the Environment*, 13(1):28–36, 2015.
- [11] L Sant’anna Bins, Leila M Garcia Fonseca, Guaraci José Erthal, and F Mitsuo Ii. Satellite imagery segmentation: a region growing approach. *Simpósio Brasileiro de Sensoriamento Remoto*, 8(1996):677–680, 1996.
- [12] Nino Boccara, Kyeong Cheong, and Mark Oram. A probabilistic automata network epidemic model with births and deaths exhibiting cyclic behaviour. *Journal of Physics A: Mathematical and General*, 27(5):1585, 1994.
- [13] Moncef Bouaziz, Mathias Leidig, and Richard Gloaguen. Optimal parameter selection for qualitative regional erosion risk monitoring: A remote sensing study of se ethiopia. *Geoscience Frontiers*, 2(2):237–245, 2011.
- [14] PAN BRASIL. Programa de ação nacional de combate à desertificação e mitigação dos efeitos da seca. *PAN-Brasil. Brasília: Ministério do Meio Ambiente*, 2004.
- [15] Fred Brauer, Carlos Castillo-Chavez, and Carlos Castillo-Chavez. *Mathematical models in population biology and epidemiology*, volume 40. Springer, 2001.
- [16] Young Gi Byun, You Kyung Han, and Tae Byeong Chae. A multispectral image segmentation approach for object-based image classification of high resolution satellite imagery. *KSCE Journal of Civil Engineering*, 17(2):486–497, 2013.
- [17] Gilberto Câmara, Ricardo Cartaxo Modesto Souza, Ubirajara Moura Freitas, and Juan Garrido. Spring: Integrating remote sensing and gis by object-oriented data modelling. *Computers & graphics*, 20(3):395–403, 1996.
- [18] Cem Canel, Basheer M Khumawala, Japhett Law, and Anthony Loh. An algorithm for the capacitated, multi-commodity multi-period facility location problem. *Computers & Operations Research*, 28(5):411–427, 2001.
- [19] Vincenzo Capasso and Gabriella Serio. A generalization of the kermack-mckendrick deterministic epidemic model. *Mathematical Biosciences*, 42(1):43–61, 1978.

- [20] Cláudio Elias Carvalho. *Desenvolvimento de Procedimentos e Métodos para Mensuração e Incorporação das Externalidades em Projetos de Energia Elétrica: Uma Aplicação às Linhas de Transmissão Aéreas*. PhD thesis, Universidade de São Paulo, 2005.
- [21] Bernard CK Choi and Anita WP Pak. Multidisciplinary, interdisciplinarity and transdisciplinarity in health research, services, education and policy: 1. definitions, objectives, and evidence of effectiveness. *Clinical and investigative medicine*, 29(6):351, 2006.
- [22] Ilsu Choi and Sung-Suk Rhee. A transmission distribution estimation for real time ebola virus disease epidemic model. *Journal of the Korean Data and Information Science Society*, 26(1):161–168, 2015.
- [23] Ulisses EC Confalonieri, Anna Carolina L Lima, Isabela Brito, and Ana Flávia Quintão. Social, environmental and health vulnerability to climate change in the brazilian northeastern region. *Climatic Change*, 127(1):123–137, 2014.
- [24] John Conway. The game of life. *Scientific American*, 223(4):4, 1970.
- [25] Ian Cooper. Transgressing discipline boundaries: is bequest an example of 'the new production of knowledge'? *Building Research & Information*, 30(2):116–129, 2002.
- [26] SHF Cunha, JP Costa, and S Prado. Modelo decomp-cepel-manual de referência. *Rio de Janeiro*, 1999.
- [27] Hernande Pereira da Silva. Mapeamento das áreas sob risco de desertificação no semi-árido de pernambuco a partir de imagens de satélites. 2009.
- [28] Hernande Pereira da Silva, Izabel Cristina de Luna Galindo, Clériston Silva dos Anjos, Rayanna Barroso de Oliveira Alves, Guilherme Monteiro de Medeiros, and Sílvio de Araújo Braga Júnior. Mapeamento de áreas degradadas a partir do mosaico landsat com solos susceptíveis à desertificação. 2015.
- [29] Ivaldo De Araujo, Hernande Pereira Da Suilva, Annelise da Silva Lopes, Bruna Patrícia Barbosa De Alencar, and Hilo Douglas Bezerra Da Silva. Cálculo de ndvi no suporte ao estudo de desertificação no município de orocó-pe. 2010.

- [30] Tiago de Azevedo Santos, Dalessandro Soares Vianna, and Marcilene de Fátima Dianin Vianna. Heurística grasp para o problema de p-medianas aplicado à localização de concentradores. *Vértices*, 13(3):31–40, 2011.
- [31] Aline Mide Romano de Barros. Modelos matemáticos de equações diferenciais ordinárias aplicados à epidemiologia. *Revista de Ciências Exatas e Tecnologia*, 2(2):62–67, 2007.
- [32] Douglas Alexander Alves de Farias. *Previsão da Carga de Energia Diária em Patamares Combinando Técnicas Estatísticas e de Inteligência Artificial*. PhD thesis, PUC-Rio, 2008.
- [33] Richard W Eglese and Graham K Rand. *Developments in Operational Research: Frontiers of Operational Research and Applied Systems Analysis*. Elsevier, 2014.
- [34] Samira El Yacoubi, S Gourbière, et al. The spatial reproduction number in a cellular automaton model for vector-borne diseases applied to the transmission of chagas disease. *Simulation*, 92(2):141–152, 2016.
- [35] Ling Feng, Yanqing Hu, Baowen Li, H Eugene Stanley, Shlomo Havlin, and Lidia A Braunstein. Competing for attention in social media under information overload conditions. *PloS one*, 10(7):e0126090, 2015.
- [36] Elaine Cristina Ferruzzi and Lourdes Maria Werle de Almeida. *Diálogos em modelagem matemática*. 2015.
- [37] Vânia Santos Figueiredo. Perspectivas de recuperação de solo para áreas em processo de desertificação no semiárido da paraíba - brasil. *Revista Electrónica de Geografía Y Ciencias Sociales*, 17(453), 2013.
- [38] Roger Fletcher. *Practical methods of optimization*. John Wiley & Sons, 2013.
- [39] Christodoulos A Floudas. *Nonlinear and mixed-integer optimization: fundamentals and applications*. Oxford University Press, 1995.
- [40] Emmanuel Fragniere and Jacek Gondzio. Optimization modeling languages. *Handbook of Applied Optimization*, pages 993–1007, 2002.

- [41] Karl Frauendorfer, Hans Glavitsch, and Rainer Bacher. *Optimization in Planning and Operation of Electric Power Systems: Lecture Notes of the SVOR/ASRO Tutorial Thun, Switzerland, October 14–16, 1992*. Springer Science & Business Media, 2013.
- [42] Shih Ching Fu. Modelling epidemic spread using cellular automata. *University of Western Australia*, 2002.
- [43] Henrique F Gagliardi, Fabrício AB da Silva, and Domingos Alves. Automata network simulator applied to the epidemiology of urban dengue fever. In *Computational Science–ICCS 2006*, pages 297–304. Springer, 2006.
- [44] Izabel Cristina de Luna Galindo. Relações solo-vegetação em áreas sob processo de desertificação no estado de pernambuco. 2007.
- [45] GAMS. Disponível em <<http://www.gams.com/>>. Acesso em janeiro de 2016, 2016.
- [46] Richard J Gaylord and Kazume Nishidate. *Modeling nature: Cellular automata simulations with Mathematica®*. Springer, 2013.
- [47] Paul A Geroski. Models of technology diffusion. *Research policy*, 29(4):603–625, 2000.
- [48] Rafael C Gonzalez and Richard E Woods. Digital image processing, 2002.
- [49] Clélia Fabiana Bueno Guedes. *Políticas públicas de estímulo à P&D: uma avaliação dos resultados do programa regulado pela Agência Nacional de Energia Elétrica–ANEEL*. PhD thesis, Universidade de Brasília, 2010.
- [50] Ian G Hamilton, Alex J Summerfield, Robert Lowe, Paul Ruyssevelt, Clifford A Elwell, and Tadj Oreszczyn. Energy epidemiology: a new approach to end-use energy demand research. *Building Research & Information*, 41(4):482–497, 2013.
- [51] Tiberiu Harko, Francisco SN Lobo, and MK Mak. Exact analytical solutions of the susceptible-infected-recovered (sir) epidemic model and of the sir model with equal death and birth rates. *Applied Mathematics and Computation*, 236:184–194, 2014.
- [52] Ch Hauert. Effects of space in 2×2 games. *International Journal of Bifurcation and Chaos*, 12(07):1531–1548, 2002.
- [53] Herbert W Hethcote. The mathematics of infectious diseases. *SIAM review*, 42(4):599–653, 2000.

- [54] A Holko, M Mdrek, Z Pastuszak, and K Phusavat. Epidemiological modeling with a population density map-based cellular automata simulation system. *Expert Systems with Applications*, 48:1–8, 2016.
- [55] Deyi Hou, David O’Connor, and Abir Al-Tabbaa. Modeling the diffusion of contaminated site remediation technologies. *Water, Air, & Soil Pollution*, 225(9):1–6, 2014.
- [56] Aníbal Alberto Vilcapoma Ignácio and Virgílio José Martins Ferreira Filho. Seção de software: o uso de software de modelagem aimms na solução de problemas de programação matemática. *Pesquisa Operacional*, 24(1):197–210, 2004.
- [57] Robert M Itami. Simulating spatial dynamics: cellular automata theory. *Landscape and urban planning*, 30(1):27–47, 1994.
- [58] Alexandra Cristina Vidal Januário. *O mercado de energia elétrica de fontes incentivadas: proposta para sua expansão e implicações na câmara de comercialização de energia elétrica*. PhD thesis, Universidade de São Paulo, 2007.
- [59] Caio LTF Jardim, Letcia AF Ferreira, Derek B Prates, and Jaqueline M Silva. Estudo da influenza a (h1n1) aplicada ao modelo sirs. *Proceeding Series of the Brazilian Society of Computational and Applied Mathematics*, 2(1), 2014.
- [60] Josef Kallrath. *Modeling languages in mathematical optimization*, volume 88. Springer Science & Business Media, 2013.
- [61] Jon Kleinberg. The convergence of social and technological networks. *Communications of the ACM*, 51(11):66–72, 2008.
- [62] Eugene L Lawler and David E Wood. Branch-and-bound methods: A survey. *Operations research*, 14(4):699–719, 1966.
- [63] IOB Leite, JCS Lins, and MGC Cerqueira. Autômatos celulares. *Documento Eletrônico* <http://www.di.ufpe.br/~iobl/monografia/index.html> [em 27/07/02].
- [64] P Li and X Xiao. Multispectral image segmentation by a multichannel watershed-based approach. *International Journal of Remote Sensing*, 28(19):4429–4452, 2007.
- [65] LINDO. Disponível em <<http://www.lindo.com/>>. Acesso em janeiro de 2016, 2016.

- [66] Alessandra Lisita, Edson Eyji Sano, and Laurent Durieux. Detection of cannabis sativa plantations in the semi-arid region of pernambuco state in brazil based on the analysis of temporal dynamic anomalies of vegetation index derived from spot-5 hrg satellite data. *Boletim de Ciências Geodésicas*, 19(1):45–64, 2013.
- [67] Yan Liu. *Modelling urban development with geographical information systems and cellular automata*. CRC Press, 2008.
- [68] Yang Liu and Taoyuan Wei. Epidemic, rank, stock and order effects in renewable energy diffusion: a model and empirical evidence from the china’s wind power sector. 2015.
- [69] João Eduardo Gonçalves Lopes. *Modelo de planejamento da operação de sistemas hidrotérmicos de produção de energia elétrica*. PhD thesis, Universidade de São Paulo, 2007.
- [70] Mônica Helena Ribeiro Luiz. Modelos matemáticos em epidemiologia. 2012.
- [71] Maria Elvira Pineiro Maceira, VS Duarte, DDJ Penna, LAM Moraes, and ACG Melo. Ten years of application of stochastic dual dynamic programming in official and agent studies in brazil-description of the newave program. *16th PSCC, Glasgow, Scotland*, pages 14–18, 2008.
- [72] Philip K Maini. Essential mathematical biology. *Mathematical Medicine & Biology: A Journal of the IMA*, 20(2), 2003.
- [73] Paul Manneville, Nino Boccara, Gérard Y Vichniac, and Roger Bidaux. *Cellular Automata and Modeling of Complex Physical Systems: Proceedings of the Winter School, Les Houches, France, February 21–28, 1989*, volume 46. Springer Science & Business Media, 2012.
- [74] Carolina Malala Martins. Atributos de solos e sua relação com o processo de desertificação no semi-árido de pernambuco. 2009.
- [75] Carolina Malala Martins, Izabel Cristina de Luna Galindo, Edivan Rodrigues de Souza, and Henrique Arruda Poroca. Atributos químicos e microbianos do solo de áreas em processo de desertificação no semiárido de pernambuco. *Revista Brasileira de Ciência do Solo*, 34(6):1883–1890, 2010.

- [76] Valdiane Moreira Martins and Josandra Araújo Barreto de Melo. Uso das terras e desencadeamento de processos de desertificação em área do semiárido brasileiro. *Revista de Geografia (Recife)*, 29(3):84–94, 2012.
- [77] E Massad. Epidemiologia matemática. *Médicos HC-FMUSP Ano I*, 3:76–81, 1998.
- [78] Cristiano G Melo, Breno AF Miranda, Silvana Bocanegra, Jones O Albuquerque, Marco Antônio A de Souza, and Constança S Barbosa. Simulação da expansão da esquistossomose no litoral de per-nambuco utilizando dois autômatos celulares probabilísticos.
- [79] Gledson Melotti. *Aplicação de Autômatos Celulares em Sistemas Complexos: Um Estudo de Caso em Espalhamento de Epidemias*. PhD thesis, Universidade Federal de Minas Gerais, 2009.
- [80] Lincoln Fernando Lautenscgkager Moro. Técnicas de otimização mista-inteira para o planejamento e programação de produção em refinarias de petróleo. *São Paulo, SP: Universidade de São Paulo*, 2000.
- [81] MPL. Disponível em <<http://www.maximal-usa.com/mpl/>>. Acesso em janeiro de 2016, 2016.
- [82] James D Murray. Mathematical biology i: An introduction, vol. 17 of interdisciplinary applied mathematics, 2002.
- [83] Paulo Nobre. Mudanças climáticas e desertificação: os desafios para o estado brasileiro. *Desertificação e Mudanças Climáticas no Semiárido Brasileiro*, pages 25–35, 2011.
- [84] Gabriel Baptista Nunes, Márcia de Azevedo Silva, and Adolpho Braga Marinho Neto. Uso de painéis solares e sua contribuição para preservação do meio ambiente. *Bolsista de Valor*, 1(1):157–162, 2013.
- [85] Fabiana Pacheco. Energias renováveis: breves conceitos. *Conjuntura e Planejamento*, 149:4–11, 2006.
- [86] MS Peixoto and LC Barros. Um estudo de autômatos celulares para o espalhamento geográfico de epidemias com parâmetro fuzzy doi: 10.5540/tema. 2004.05. 01.0125. *Trends in Applied and Computational Mathematics*, 5(1):125–133, 2004.
- [87] Roney Peterson Pereira. Introdução a programação linear. 2013.

- [88] Jean E Pretz, Adam J Naples, and Robert J Sternberg. Recognizing, defining, and representing problems. *The psychology of problem solving*, 30(3), 2003.
- [89] Marli Teresinha Quartieri. Estudo de modelos epidemiológicos determinísticos básicos em doenças causadas por microparasitas. 2004.
- [90] James F Reynolds, D Mark Stafford Smith, Eric F Lambin, BL Turner, Michael Mortimore, Simon PJ Batterbury, Thomas E Downing, Hadi Dowlatabadi, Roberto J Fernández, Jeffrey E Herrick, et al. Global desertification: building a science for dry-land development. *science*, 316(5826):847–851, 2007.
- [91] R Tyrrell Rockafellar. Basic issues in lagrangian optimization. In *Optimization in Planning and Operation of Electric Power Systems*, pages 3–30. Springer, 1993.
- [92] G Rousseau, B Giorgini, R Livi, and H Chaté. Dynamical phases in a cellular automaton model for epidemic propagation. *Physica D: Nonlinear Phenomena*, 103(1):554–563, 1997.
- [93] Rudy Rucker. The lifebox, the seashell, and the soul. *Thunder’s Mouth Press, New York*, 2005.
- [94] IB Sá, II da S Sá, and A de S Silva. Desertificação na região de cabrobó-pe: a realidade vista do espaço. *Simpósio Regional de Geoprocessamento e Sensoriamento Remoto*, 3:2006, 2006.
- [95] Iêdo Bezerra SA and Ivan Ighour Silva SÁ. A cobertura vegetal do bioma caatinga: subsídios ao monitoramento de processos de desertificação. In *Embrapa Semiárido- Artigo em anais de congresso*. In: Seminário de Atualização em Sensoriamento Remoto e Sistemas de Informações Geográficas Aplicados à Engenharia Florestal, 8., 2008, Curitiba. Anais... Curitiba: FUPEF, 2008., 2009.
- [96] Ugur Sahin, Selman Uguz, Hasan Akin, and Irfan Siap. Three-state von neumann cellular automata and pattern generation. *Applied Mathematical Modelling*, 39(7):2003–2024, 2015.
- [97] Marta Celina Linhares Sales. Panorama da desertificação no brasil. *Agricultura familiar e desertificação*. João Pessoa, Editora universitária/UFPB, pages 33–50, 2006.
- [98] Alexander Schatten. Cellular automata: Digital worlds. Retrieved February, 13:2004, 1999.

- [99] Pedro Henrique Triguís Schimit. *Modelagem e controle de propagação de epidemias usando autômatos celulares e teoria de jogos*. PhD thesis, Universidade de São Paulo, 2010.
- [100] Fernando Semboloni. An urban and regional model based on cellular automata. *Environment and Planning B*, 24:589–612, 1997.
- [101] Gary A Shaw and Hsiao-hua K Burke. Spectral imaging for remote sensing. *Lincoln Laboratory Journal*, 14(1):3–28, 2003.
- [102] Remy Sietchiping. A geographic information systems and cellular automata-based model of informal settlement growth. 2004.
- [103] G Ch Sirakoulis, Ioannis Karafyllidis, and Adonios Thanailakis. A cellular automaton model for the effects of population movement and vaccination on epidemic propagation. *Ecological Modelling*, 133(3):209–223, 2000.
- [104] Bartolomeu Israel Souza and Dirce MA Suertegaray. Estratégias de sobrevivência do pequeno produtor em áreas sujeitas à desertificação no semiárido brasileiro. *Passages de Paris*, 6:365–386, 2011.
- [105] Hamdy A Taha. *Integer programming: theory, applications, and computations*. Academic Press, 2014.
- [106] Domenico Talia and Peter Sloot. Cellular automata: Promise and prospects in computational science. *Future generation computer systems*, 16(2):v–vii, 1999.
- [107] Robert J Vanderbei. *Linear programming*. Springer, 2014.
- [108] João Vasconcelos Sobrinho. Núcleos de desertificação no polígono das secas. *Anais do ICB*, 1, 1971.
- [109] John Von Neumann. The general and logical theory of automata. *Cerebral mechanisms in behavior*, pages 1–41, 1951.
- [110] S Hoya White, A Martín del Rey, and G Rodríguez Sánchez. Modeling epidemics using cellular automata. *Applied Mathematics and Computation*, 186(1):193–202, 2007.
- [111] H Paul Williams. *Model building in mathematical programming*. John Wiley & Sons, 2013.

-
- [112] Stephen Wolfram. Cellular automata as simple self-organizing systems. *Caltech preprint CALT-68-938*, 5, 1982.
- [113] Stephen Wolfram. Statistical mechanics of cellular automata. *Reviews of modern physics*, 55(3):601, 1983.
- [114] Stephen Wolfram. Cellular automata as models of complexity. *Nature*, 311(5985):419–424, 1984.
- [115] Stephen Wolfram. *Cellular automata and complexity: collected papers*, volume 1. Addison-Wesley Reading, 1994.
- [116] Stephen Wolfram. *A new kind of science*, volume 5. Wolfram media Champaign, 2002.
- [117] Jiyoung Woo, Jaebong Son, and Hsinchun Chen. An sir model for violent topic diffusion in social media. In *Intelligence and Security Informatics (ISI), 2011 IEEE International Conference on*, pages 15–19. IEEE, 2011.
- [118] Hyun Mo Yang. *Epidemiologia matemática: estudos dos efeitos da vacinação em doenças de transmissão direta*. Unicamp, 2001.
- [119] Behzad Zahiri, Reza Tavakkoli-Moghaddam, and Mir Saman Pishvaei. A robust possibilistic programming approach to multi-period location–allocation of organ transplant centers under uncertainty. *Computers & Industrial Engineering*, 74:139–148, 2014.
- [120] Machi Zawidzki. Dynamic shading of a building envelope based on rotating polarized film system controlled by one-dimensional cellular automata in regular tessellations (triangular, square and hexagonal). *Advanced Engineering Informatics*, 29(1):87–100, 2015.

Apêndice A

Dicionário de dados e resultados desta dissertação.

Este dicionário de dados indica os arquivos para obtenção dos dados utilizados na pesquisa.

Os arquivos aqui mencionados estão disponíveis através da página:

<https://sourceforge.net/projects/acenergy/>

A.1 Desert-MAP

Os resultados do Desert-MAP serão disponibilizados posteriormente através do link:

<http://www.spectralmaps.com/desert/>

A.2 Modelagem de Otimização

A.2.1 SETs

O arquivo "usinas.xlsx" contém os conjuntos utilizados no modelo de otimização para despacho das usinas térmicas.

A.2.2 Arquivos base do modelo NEWAVE

Os arquivos base do modelo NEWAVE são disponibilizados periodicamente pela Biblioteca Virtual da Câmara de Comercialização de Energia Elétrica (CNEE), através do link:

http://www.ccee.org.br/portal/faces/aceso_rapido_header_publico_nao_logado/biblioteca_virtual

Os arquivos CLAST.DAT e TERM.DAT contém os dados das classes térmicas referentes ao período da simulação.

A.2.3 Demanda ONS

A demanda horária disponibilizada pelo ONS e utilizado nessa pesquisa está no arquivo: "Carga Horária`MW`hh`jan-14`dez-15.xlsx".

A.2.4 Boletim diário ONS

O Boletim diário da Operação do SIN pode ser acessado através do link:

http://www.ons.org.br/resultados_operacao/boletim_diario/

A.3 Modelagem Epidemiológica

A.3.1 Planilhas de demanda do Grupo Neoenergia

As planilhas de demanda disponibilizadas pelo Grupo Neoenergia podem ser consultadas pelos arquivos: "Mercado Celpe - Município e Classe de Consumo.xlsx" e "Municipios Anual-2012`2011`2010 - Livre+Cativo.xls".

A.3.2 Distribuição celular

A distribuição demográfica das cidades que compõem a demanda, realizadas pelo autor, podem ser acessadas pelo arquivo "matrizPE.xlsx".