

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
DEPARTAMENTO ACADÊMICO DE INFORMÁTICA
CURSO DE ENGENHARIA DE COMPUTAÇÃO**

BRUNA ELOISE HINRICHS

**UMA SOLUÇÃO UTILIZANDO ALGORITMO GENÉTICO PARA O
PROBLEMA DE COMPROMETIMENTO DE UNIDADES DE ENERGIA**

TRABALHO DE CONCLUSÃO DE CURSO

PATO BRANCO

2018

BRUNA ELOISE HINRICHS

**UMA SOLUÇÃO UTILIZANDO ALGORITMO GENÉTICO PARA O
PROBLEMA DE COMPROMETIMENTO DE UNIDADES DE ENERGIA**

Trabalho de Conclusão de Curso como requisito parcial à obtenção do título de Bacharel em Engenharia de Computação, do Departamento Acadêmico de Informática da Universidade Tecnológica Federal do Paraná.

Orientador: Prof. Dr. Dalcimar Casanova

PATO BRANCO

2018



TERMO DE APROVAÇÃO

Às 10 horas e 30 minutos do dia 13 de dezembro de 2018, na sala V006, da Universidade Tecnológica Federal do Paraná, Câmpus Pato Branco, reuniu-se a banca examinadora composta pelos professores Dalcimar Casanova (orientador), Beatriz Terezinha Borsoi e Marco Antonio de Castro Barbosa para avaliar o trabalho de conclusão de curso com o título **Uma Solução Utilizando Algoritmo Genético para o Problema de Comprometimento de Unidades de Energia**, da aluna **Bruna Eloise Hinrichs** matrícula 01587331, do curso de Engenharia de Computação. Após a apresentação a candidata foi arguida pela banca examinadora. Em seguida foi realizada a deliberação pela banca examinadora que considerou o trabalho aprovado.

Prof. Dalcimar Casanova
Orientador (UTFPR)

Profa. Beatriz Terezinha Borsoi
(UTFPR)

Prof. Marco Antonio de Castro Barbosa
(UTFPR)

Profa. Beatriz Terezinha Borsoi
Coordenador de TCC

Prof. Pablo Gauterio Cavalcanti
Coordenador do Curso de
Engenharia de Computação

A Folha de Aprovação assinada encontra-se na Coordenação do Curso.

Dedico este trabalho primeiramente a minha família em especial aos meus pais Roberto J.Hinrichs e Silvana Ceratti, por me apoiarem e não medirem esforços para que eu conseguisse chegar até esta conquista, a minha irmã Bianca L. Hinrichs por me dar apoio e trazer alegria durante esta jornada, e também a Tiago Ludtke por estar ao meu lado dando auxílio para conseguir finalizar esta jornada.

AGRADECIMENTOS

Agradeço ao Professor Dalcimar pela sua orientação e ajuda para entendimento de conceitos relacionados a este trabalho.

Agradeço aos meus amigos que estiveram nessa batalha comigo, que sempre me apoiaram e me proporcionaram os melhores desta jornada.

A persistência é o menor caminho do êxito
Charles Chaplin

RESUMO

HINRICHS, Bruna Eloise. Uma Solução Utilizando Algoritmo Genético para o Problema de Comprometimento de Unidades de Energia 2018. 46f. Trabalho de Conclusão de Curso de bacharelado em Engenharia de Computação - Universidade Tecnológica Federal do Paraná. Pato Branco, 2018.

A geração de energia evoluiu, passando para uma produção descentralizada com uma matriz energética diversificada por energias renováveis. Com esta evolução os métodos de controle convencionais empregados deixaram de ser ideais. Este trabalho aborda um dos problemas que surgiu com essa evolução que é o comprometimento de unidade responsável por determinar o cronograma de geração das unidades geradoras em um horizonte de tempo pré-estabelecido. E este trabalho explora os métodos de solução já empregados e propõe um método de otimização utilizando algoritmo genético. Esse método é responsável por avaliar e ponderar os recursos disponíveis nas unidades geradoras em um intervalo de tempo pré-estabelecido, tendo sua viabilidade verificada com conjunto de dados de teste.

Palavras-chave: Algoritmo genético. Comprometimento de unidades de energia. Energia renovável.

ABSTRACT

HINRICHS, Bruna Eloise. A Solution Using Genetic Algorithm for the Problem Units Commitment of Energy. 2018. 46f. Trabalho de Conclusão de Curso de bacharelado em Engenharia de Computação - Universidade Tecnológica Federal do Paraná. Pato Branco, 2018.

Energy generation has evolved into decentralized production with an energy matrix diversified by renewable energies. With this evolution the conventional control methods employed are no longer ideal. This work addresses one of the problems that arose with this evolution, which is the commitment of the unit responsible for determining the generation schedule of generating units in a pre-established time horizon. And this work explores the already used solution methods and proposes a method of optimization using genetic algorithm. This method is responsible for evaluating and weighing the available resources in the generating units in a pre-established time interval, having its viability verified with the set of test data.

Keywords: Unit commitment. Genetic algorithm. Renewable energy.

LISTA DE FIGURAS

Figura 1 – Modelo de controle e comunicação do sistema de geração de energia.....	30
Figura 2 - Representação de um cromossomo.....	33
Figura 3 – Evolução da função de avaliação.....	40
Figura 4 - Evolução da função de custo total	41

LISTA DE TABELAS

Tabela 1 - Dados das Unidades Geradoras.....	36
Tabela 2 - Demanda para o Cronograma de 24 horas.....	37
Tabela 3 - Resultados teste de 1 a 3.....	37
Tabela 4 - Resultados teste de 4 a 6.....	37
Tabela 5 - Resultados teste de 7 a 9.....	38
Tabela 6 - Potências geradas em cada unidade por hora.....	39
Tabela 7 - Potências totais geradas por hora	40

LISTA DE SIGLAS E ABREVIATURAS

AG	Algoritmo genético
PSO	<i>Particle Swarm Optimization</i>
SA	<i>Simulated Annealing</i>
QEA	<i>Quantum-Inspired Evolutionary Algorithm</i>
DE	<i>Differential Evolution</i>
EA	<i>Evolutionary Algorithms</i>
IPSO	<i>Improved Particle Swarm Optimization Algorithm</i>
ABC	<i>Artificiais ou Artificial Bee Colony</i>
FF	<i>Firefly</i>
BPOS	<i>Binary Particle Swarm Optimization</i>
QBPOS	<i>namely quantum-inspired BPSO</i>
MPSO	<i>Mutated Particle Swarm Optimization Algorithm</i>
UC	Unit Commitment
UFV	Usina Fotovoltaica
UHE	Usina Hidroelétrica
MME	Ministério de Minas e Energia
SIN	Sistema Elétrico Interligado Nacional
Proinfa	Programa de Incentivo às Fontes Alternativas de Energia Elétrica
PCH	Pequenas Centrais Hidrelétricas
INEE	Instituto Nacional de Eficiência Energética
ER	Energia Renovável
EPE	Empresa de Pesquisa Energética
CGH	Centrais Geradoras Hidroelétricas
ANEE	Agência Nacional de Energia Elétrica
CTP	Custo total de produção da geração de energia;
FC	Função de custo de combustível da unidade de geração
N	Numero de unidades geradoras
H	Numero de horas do cronograma de geração de energia
$P_{i,h}$	Potencia de geração na unidade i e na hora h ;
ST_i	Custo de arranque da unidade;
$U_{i,h}$	Estado ligado / desligado da unidade i na hora h ;
D_h	Demanda de carga na hora h ;

R_h	Reserva na hora h ;
$P_{i, \min}$	Limite mínimo de geração da unidade;
$P_{i, \max}$	Limite máximo de geração da unidade;
MI_i	Tempo mínimo de funcionamento da unidade;
MD_i	Tempo de inatividade mínimo da unidade;
F	Função de avaliação
FC_i	Função de custo de combustível
SC_i	Custo de arranque das unidades geradoras
SD_i	Custo de desligamento das unidades geradoras
NC	Número de restrições operacionais violadas
PF_i	Penalidade associada à restrição violada
μ_i	Coeficiente associado a penalidade
V_i	Numero de violações
ST_{quente}	Custo de inicialização a quente da unidade geradora
ST_{Frio}	Custo de inicialização a frio da unidade geradora
STh_{Frio}	Quantidade de horas consideradas inicialização a frio da unidade geradora
SI	Status inicial

SUMÁRIO

1	INDRODUÇÃO.....	13
1.1	CONSIDERAÇÕES INICIAIS	13
1.2	OBJETIVOS	14
1.2.1	Objetivo Geral	14
1.2.2	Objetivos Específicos	14
1.3	JUSTIFICATIVA.....	14
2	REFERENCIAL TEÓRICO.....	16
2.1	Setor elétrico brasileiro.....	16
2.1.1	Energia solar.....	17
2.1.2	Energia eólica	17
2.1.3	Energia hidráulica	18
2.1.4	Biomassa.....	19
2.2	Métodos de solução para o problema de uc.....	19
2.2.1	Métodos numéricos de solução	20
2.2.2	Método utilizando Redes Neurais Artificiais	21
2.2.3	método utilizando Sistemas Fuzzy	22
2.2.4	Método utilizando Otimização de Enxame de Partículas.....	22
2.2.5	Método utilizando Recozimento Simulado.....	23
2.2.6	método utilizando Algoritmo Evolucionário de inspiração Quântica	24
2.2.7	Método utilizando Evolução Diferencial	24
2.2.8	Método utilizando Colônia Artificial de Abelha.....	24
2.2.9	Método utilizando Algoritmo Vagalume.....	25
2.2.10	Método utilizando Algoritmo Genético.....	25
2.3	Algoritmo genético	26
2.3.1	Inicialização	27
2.3.2	Função de Avaliação	27
2.3.3	Seleção	27
2.3.4	Operadores genéticos.....	28
2.3.4.1	<i>Crossover</i>	28
2.3.4.2	Mutação	29
3	METODOLOGIA	30
3.1	Sistema.....	30
3.2	Formulação do problema de UC	31
3.3	Algoritmo Genético aplicado a o problema de UC	33
3.3.1	Inicialização	33
3.3.2	Seleção	34
3.3.3	Operadores genéticos.....	34
4	RESULTADOS.....	36
5	CONCLUSÃO	41
6	REFERÊNCIAS	43

1 INTRODUÇÃO

1.1 CONSIDERAÇÕES INICIAIS

O desenvolvimento sustentável é uma das grandes preocupações governamentais deste século e envolve grandes setores como o de transporte, agrícola, industrial e energético. O setor energético, em particular, por estar ligado ao crescimento dos demais setores e por estar intrinsecamente relacionado ao desenvolvimento econômico, se torna ponto chave para alcançar o objetivo de diminuir a emissão de gases do efeito estufa.

A matriz energética de um país é composta por dois tipos de fontes de geração de energia: as renováveis e não renováveis. As fontes consideradas renováveis possuem a capacidade de reposição no ambiente mais rápida do que seu consumo, como, por exemplo, as fontes hidráulicas, biomassa, solar, eólica e geotérmica. As fontes não renováveis têm sua capacidade de reposição no ambiente lenta em comparação ao seu consumo e incluem exemplos como petróleo, gás natural e carvão mineral (REIS, 2011).

A busca por uma matriz energética limpa, utilizando apenas sistemas de energias renováveis (ERs), ocasiona o aumento da produção da energia distribuída perante a produção de energia centralizada. A geração centralizada é baseada em grandes centrais de geração, principalmente termelétricas e hidrelétricas conectadas a uma extensa rede de linhas de transmissão (SP, s.d.). Já a produção distribuída é caracterizada por fontes de energia elétrica conectadas diretamente às redes próximas dos consumidores. A produção distribuída envolve aspectos como, eficiência, confiabilidade, custo da conversão de energia, capacidade de prever a produção de energia, capacidade de gerenciar microrredes, armazenamento eficiente de energia e transporte (LISERRE; SAUTER; HUNG, 2010).

Para atender a demanda do sistema elétrico e tornar significativa a produção descentralizada, torna-se necessário analisar os problemas de comprometimento da unidade (*Unit commitment* - UC) que compõem o sistema de geração distribuída. O problema de UC trata de determinar os cronogramas de partida e parada de unidades geradoras a serem usadas para atender a demanda prevista em curto prazo (KAZARLIS; BAKIRTZIS; PETRIDIS, 1996), com objetivo de obter a melhor combinação entre as unidades geradoras para suprir a necessidade dos consumidores com melhor custo benefício utilizando ERs.

O problema de UC é um problema complexo de otimização (BERTSIMAS et al., 2013), que teve alguns métodos desenvolvidos, na tentativa de obter a melhor solução. Dentre os métodos desenvolvidos estão: enumeração completa, programação dinâmica, relaxamento

Lagrangiano, algoritmos genéticos e enxame de partículas (YUN-WON et al., 2010). Em geral, esses métodos de otimização melhoram a sintonia entre a geração e a ponderação de recursos, mas eles não são nativamente integrados aos sistemas de controle reativo da geração, os quais de fato coordenam as ações de geração. Dessa forma, é comum que tais investigações se restrinjam a abordagens teóricas e enfrentem limitações para a conversão em ferramentas práticas.

Em oposição, as abordagens se concentram nos sistemas de controle para as redes de geração que fornecem o ferramental necessário para coordenar os esquemas de atuação dos componentes físicos, mas deixam as políticas de otimização em segundo plano, favorecendo o sistema reativo puro, não otimizado. É desse desencontro entre grandes áreas que nasce esse trabalho, caracterizado como se segue.

1.2 OBJETIVOS

1.2.1 Objetivo Geral

Propor um método de otimização que avalie e pondere a demanda de geração e os recursos disponíveis na microrrede e nas unidades geradoras em um intervalo de tempo pré-estabelecido. Assim, o esquema de otimização propõe o melhor cenário de geração, com melhor custo benefício.

1.2.2 Objetivos Específicos

Dentre os objetivos específicos destacam-se:

- Investigação sobre algoritmos viáveis para otimizar UC;
- Desenvolvimento de um algoritmo genético para otimizar UC;
- Estudo de operadores genéticos complementares para melhorar a resposta obtida pelo algoritmo genético;
- Análise dos resultados obtidos.

1.3 JUSTIFICATIVA

O setor elétrico brasileiro tem passado por mudanças desde a década de 90. O aumento dos investimentos e a criação de novos programas, como o Programa de Incentivo às Fontes

Alternativas de Energia Elétrica (Proinfa), segundo o Decreto nº 5.025. Esse projeto tem o objetivo de aumentar a participação da energia elétrica produzida por fontes de energia eólica, biomassa e pequenas centrais hidrelétricas (PCH) no Sistema Elétrico Interligado Nacional (SIN) (MME, s.d.). Os incentivos à produção de energia pelo consumidor também aumentaram, o que sugere que a produção de energia distribuída vem ganhando força (INEE, s.d.).

Com a adesão desses novos métodos de produção ao SIN, aumentou o número de desafios enfrentados nas áreas de controle da operação e da proteção destes sistemas. Considerando esta crescente complexidade e também o contexto atual do sistema elétrico brasileiro, as técnicas de controle, o monitoramento e a proteção dos sistemas não são mais suficientes para gerar uma resposta apropriada em tempo real aos eventos inesperados que podem ocorrer nas unidades geradoras, como os desligamentos não programados, as contingências entre outros distúrbios (ARAÚJO et al., 2009).

2 REFERENCIAL TEÓRICO

2.1 SETOR ELÉTRICO BRASILEIRO

Um sistema é um grupo de componentes inter-relacionados que trabalham juntos rumo a uma meta comum recebendo insumos e produzindo resultados em um processo organizado de transformação (O' BRIEN, 2002). O setor elétrico brasileiro inicialmente era constituído de grandes usinas geradoras de energia como as hidrelétricas, seguida das termelétricas e o restante são provenientes de usinas eólicas e importação da energia de outros países (ANEEL, s.d.b). Esse tipo de produção era enviado por grandes linhas de transmissão á subestações localizadas próximas aos centros de carga ou consumo que se responsabilizam pela distribuição da energia aos consumidores finais.

Com o progresso na geração e exploração de fontes renováveis o setor elétrico teve uma mudança na sua forma de geração de energia, instituindo a geração distribuída como uma nova alternativa. Esse tipo de geração é constituído por pequenos geradores que utilizam normalmente fontes de energia renováveis localizadas próximas dos centros de consumo. A presença desses pequenos geradores traz como benefícios baixos impactos ambientais, melhoria da tensão da rede no período de maior carga além de aumentar a diversidade da matriz energética buscada pelas politicas governamentais atuais (ANEEL, 2016).

De acordo com a normativa N° 482, vigente desde 17 de abril de 2012 pela ANNEEL, foram estabelecidas condições gerais para o acesso de microgeração e minigeração distribuídas, aos sistemas de distribuição de energia elétrica e ao sistema de compensação de energia elétrica.

A microgeração distribuída é constituída por centrais geradoras de energia elétrica, com potência instalada menor ou igual a 100 kW, que utilizam fontes com base em energia hidráulica, solar, eólica e biomassa. Como característica da microgeração destaca-se o potencial instalado e quantos geradores ainda podem ser suportados nesta microrrede.

Na minigeração distribuída as centrais geradoras de energia elétrica possuem a potência instalada superior a 100 kW e menor ou igual a 1 MW. Suas fontes de energia são as mesmas utilizadas na microgeração, destacando-se as mesmas características da microrrede.

E para compensação de energia elétrica entende-se que a energia ativa gerada por unidade consumidora com microgeração distribuída ou minigeração distribuída compense o consumo de energia elétrica ativa.

Nesta normativa destaca-se o uso de energias renováveis, as quais sofrem grande

variação na sua produção, tornando-se necessária a análise dos fatores característicos relevantes para o controle do nível de geração a fim de se obter estabilidade do sistema. Com a intenção de se angariar as características necessárias para esse trabalho serão analisadas as principais fontes renováveis presentes na matriz energética brasileira.

2.1.1 Energia solar

A energia solar é a energia eletromagnética proveniente do sol que pode ser transformada em energia térmica ou elétrica (ECOIA, 2016). Para a produção de energia elétrica são utilizados dois tipos de sistemas, o hipotérmico que possui uma etapa intermediária convertendo primeiramente a irradiação solar em energia térmica e posteriormente em energia elétrica. E os sistemas fotovoltaicos, mais utilizados atualmente, que fazem a conversão direta da irradiação solar para energia elétrica.

A produção de energia elétrica por painéis fotovoltaicos não requer alta irradiação solar para funcionar e sua eficiência é medida pela proporção de radiação solar incidente sobre a superfície da célula que é convertida em energia elétrica (ZOMER; RUTHER, 2018). Contudo, torna-se necessário analisar fatores como densidade de nuvens e horário do dia, para estimar a produção em um dado momento.

Os sistemas fotovoltaicos podem ser instalados tanto para baixas potências como para altas potências como é o caso das usinas solares. O Brasil atualmente possui onze usinas fotovoltaicas (UFV) em funcionamento e trinta e cinco em expansão já contratadas com entregas até 2021 (EPE, s.d.). Esses dados sugerem um aumento de investimentos do setor justificado pelo potencial do país, que possui grandes áreas com radiação solar incidente e está próximo à linha do equador.

2.1.2 Energia eólica

A energia eólica é a energia mecânica proveniente da energia cinética dos ventos. Essa é uma das fontes renováveis mais utilizadas na história humana, sendo utilizada na agricultura, navegação e para geração de energia elétrica (MARTINS; GUARNIERI; PEREIRA, 2008). É considerada uma fonte de energia elétrica intermitente, ou seja, mudanças abruptas ocorrem com frequência, introduzindo uma instabilidade ao sistema de geração quando analisada separadamente.

A conversão de energia eólica é gerada a partir de aerogeradores que são os

componentes responsáveis por aproveitar a energia cinética do vento em parques eólicos e fazer sua conversão em energia mecânica das turbinas que posteriormente é transformada em energia elétrica. Os aerogeradores buscam o melhor aproveitamento fazendo uso de características de disposição contra ou a favor do vento, usando tecnologia de velocidade variável ou contínua (PAO; JOHNSON, 2009). É necessário o monitoramento da velocidade dos ventos para evitar sobrecarga com velocidades elevadas, ou perdas com velocidades muito baixas, além dos fatores externos como estação do ano, hora do dia e características de região como o clima e paisagem.

O Brasil, por possuir um vasto território, possui grandes vantagens em todos os tipos de geração de energia por fontes renováveis, possuindo 369 usinas eólicas em funcionamento e 261 usinas contratadas para expansões do SIN (EPE, s.d.).

2.1.3 Energia hidráulica

A energia hidráulica é produzida a partir da energia cinética captada da água, a qual é convertida por uma turbina hidráulica em energia mecânica, que é enviada ao gerador elétrico para conversão final em energia elétrica (GOMEZ-EXPOSITO; CONEJO; CANIZARES, 2008). Uma das grandes vantagens desse tipo de produção de energia é a sua flexibilidade em conexão e desconexão, tornando-as altamente adaptável para ajustar a produção às necessidades de demanda do setor elétrico.

As usinas hidrelétricas podem ser de dois tipos, plantas com reservatório acumulação em que água é armazenada em reservatórios que regulam o fluxo de água que é ou pode ser usado para ativar a turbina. E plantas a fio d'água em que a turbina é ativada pela afluência do rio, sem acumulação de água reservatórios (LOPES; BORGES, 2015). As pequenas centrais hidrelétricas (PCHs) são em grande parte desse tipo. Nesse tipo de geração são considerados fatores de controle como nível do rio ou reservatório, mudanças climáticas como grandes volumes de chuvas ou longos períodos de estiagem.

No caso de grandes usinas hidroelétricas, a construção de grandes reservatórios atualmente enfrenta grandes problemas ambientais ao serem construídos além do alto investimento na infraestrutura. Portanto, os novos projetos hidrelétricos em construção são geralmente usinas a fio d'água ou PCHs. No Brasil, por exemplo, existem em funcionamento entre PCHs e centrais geradoras hidroelétricas (CGHs) 141 locais enquanto possui somente 30 usinas hidroelétricas (UHE) de grande porte em funcionamento (EPE, s.d.).

2.1.4 Biomassa

A biomassa é classificada como qualquer matéria orgânica que possa ser transformada em energia mecânica, térmica ou elétrica (MASTERS, 2004). De acordo com a sua origem, pode ser: florestal, agrícola, rejeitos urbanos e industriais. Os derivados obtidos dependem tanto da matéria prima utilizada quanto da tecnologia de processamento para obtenção de energia.

Existem várias tecnologias empregadas na produção de energia elétrica a partir da biomassa. Todas fazem a conversão da matéria prima em um produto intermediário que será utilizado em uma máquina motriz. Essa máquina produzirá a energia mecânica que acionará o gerador de energia elétrica. Entre essas tecnologias destacam-se a utilização de turbinas de contrapressão e condensação, nas quais a biomassa é queimada diretamente em caldeiras e a energia térmica resultante é utilizada na produção do vapor (ANEEL, s.d.). Este vapor pode acionar as turbinas usadas no trabalho mecânico para geração de energia elétrica.

A biomassa é um tipo de energia renovável que está dentro do plano nacional de energia de 2030, como vantagens desse tipo de geração tem-se o baixo custo da matéria prima e como desvantagens, o alto custo de instalação de uma usina e o transporte da matéria prima. Com base em informações disponibilizadas pela (EPE, s.d.), estão em funcionamento 37 usinas de biomassa com expansão contratada de mais 4 usinas até 2024.

2.2 MÉTODOS DE SOLUÇÃO PARA O PROBLEMA DE UC

O problema de UC é o processo de decisão mais crítico realizado no setor de energia elétrica (BERTSIMAS et al., 2013), que consiste em estimar o cálculo do cronograma de produção das unidades geradoras disponíveis para atender suas restrições técnicas e operacionais e para atender restrições do sistema de geração e distribuição, como por exemplo, o equilíbrio global entre produção e demanda de energia. Em termos gerais tem o objetivo de minimizar o custo, ou maximizar o benefício, obtido pelo cronograma de produção das unidades geradoras em determinado horizonte de tempo (TAHANAN et al., 2015).

Desta maneira, problemas de UC variam de acordo com as características do sistema elétrico que está sendo analisado visto que cada governo impõe suas regras de operação e uma matriz energética diferente, mas de maneira geral possui elementos comuns, sendo eles:

- Um conjunto de unidades geradoras correspondentes, com seu conjunto de restrições

técnicas e ambientais;

- Um horizonte de tempo ao longo do qual as decisões devem ser tomadas, amostradas em um número finito de instantes de tempo;
- Uma previsão de carga a ser produzida e entregue às unidades consumidoras.

O UC trabalha com três tipos de tomadas de decisão, sendo elas: as decisões de compromisso, compostas por variáveis discretas que determinam se uma unidade específica está ligada ou desligada a qualquer momento as decisões de produção, constituídas de variáveis contínuas que fornecem a quantidade de potência por uma unidade específica em um dado momento; e as decisões de rede, que representam o ângulo de fase ou magnitudes de tensão descrevendo o estado da rede de transmissão ou distribuição (TAHANAN et al., 2015).

A geração renovável na UC se refere principalmente aos parques eólicos, à geração solar e às usinas hidroelétricas. A característica fundamental de todas essas fontes, no que diz respeito à UC, é o fato de que elas não podem ser facilmente modeladas devido à ação de fatores externos. Esses fatores tornam difícil o fornecimento de previsões precisas para geração renovável, mesmo para horizontes de tempos curtos, tendo que possuir uma geração extra para o caso de flutuação na geração proveniente dessas fontes.

Com o avanço tecnológico e o crescente estudo sobre UC é possível agrupar as soluções em técnicas de otimização numérica e estocástica. Dentre as técnicas de otimização numérica estão a Lista de prioridade, Programação Dinâmica e Relaxamento Lagrangeano. E entre as técnicas estocásticas estão Algoritmos Genéticos, otimização de enxame de Partículas, Recozimento Simulado, Algoritmo Evolucionário de inspiração Quântica, Evolução diferencial, Colônia Artificial de Abelha e Algoritmo Vagalume.

2.2.1 Métodos numéricos de solução

Entre os métodos numéricos de solução utilizados em problemas de UC, tem-se o método de Lista de Prioridade que divide a carga a ser produzida em ordem crescente do custo médio de carga total da unidade geradora para que as unidades de carga base mais econômicas sejam comprometidas primeiro e as unidades de pico durem para atender a demanda de carga (KAZARLIS; BAKIRTZIS; PETRIDIS, 1996). Este método tem como vantagem sua velocidade, em contrapartida o custo de produção relativamente alto como desvantagem.

O método de Programação Dinâmica também atua para resolução dos problemas de UC decompondo este problema no tempo, estipulando a cada hora quais unidades devem ser

acionadas ou desativadas. As seguintes informações são armazenadas: o custo total mínimo de produção para alcançar o estado a partir da primeira hora, um ponteiro de *link-back* ótimo apontando para aquele estado da hora anterior que resultou na transição ótima para o estado atual da hora (KAZARLIS; BAKIRTZIS; PETRIDIS, 1996). Essa solução se torna impossível para grandes sistemas, sendo necessária aplicação de métodos heurísticos para encontrar uma solução subótima. Este método tem como desvantagem a dificuldade no tratamento de restrições que dependem do tempo.

Outro método numérico de solução é o Relaxamento Lagrangeano, o qual faz uso dos multiplicadores de Lagrange para as restrições do sistema e adiciona os termos de penalidade associados na função objetivo para formar a função Lagrangeana. Para valores fixos dos multiplicadores de Lagrange, a função é separável por unidade geradora, podendo ser decomposta em N problemas, onde N é o número de unidades, reduzindo assim a complexidade do problema (KAZARLIS; BAKIRTZIS; PETRIDIS, 1996). Este método é utilizado para encontrar a otimização da operação de cada unidade durante o horizonte de tempo, o que não garante encontrar a otimização do sistema como um todo.

2.2.2 Método utilizando Redes Neurais Artificiais

As redes neurais artificiais são modelos matemáticos inspirados na estrutura neural de um organismo inteligente (GERVEN; BOHTE, 2018). Essas redes de maneira geral são compostas por células computacionais simples denominadas neurônios ou células de processamento que são capazes de realizar cálculos massivamente paralelos para processamento de dados e representação de conhecimento (SCHALKOFF, 1997).

A semelhança com os organismos inteligentes vem da aquisição do conhecimento a partir de seu ambiente através de um processo de aprendizagem realizado a partir de um algoritmo de aprendizagem, cuja função é modificar os pesos da rede de uma forma ordenada para alcançar um objetivo desejado (HAYKIN, 2000). Neste processo, o neurônio recebe um estímulo do ambiente, processa-o e transmite-o ao próximo neurônio da rede, sendo ele um neurônio escondido, que se localiza no interior da rede ou um neurônio de saída que interage com o ambiente (BASHEER; HAJMEER, 2000).

O emprego de redes neurais artificiais inicialmente utilizava a vantagem da computação paralela em relação à computação serial. Ao longo dos anos, vários modelos de algoritmos de aprendizagem associados às redes foram desenvolvidos, explorando a possibilidade de resolver o problema de otimização combinatório, em particular para a UC

aplicando a rede neural de Hopfield (PADHY, 2004).

2.2.3 Método Utilizando Sistemas Fuzzy

A lógica Fuzzy teve seu início em meados de 1960, propondo que a natureza do pensamento humano é confusa ou imprecisa, portanto a lógica booleana que representa estados de 0 e 1 ou sim e não, não é capaz de representar adequadamente o processo de pensamento. A lógica Fuzzy propõe então uma lógica multivalorada na qual os valores de verdade das variáveis podem ser qualquer número real entre 0 e 1 (BOSE, 1994). Ela é empregada para lidar com o conceito de verdade parcial, em que o valor de verdade pode variar entre completamente verdadeiro e completamente falso.

Um sistema de controle Fuzzy é um sistema de controle baseado em lógica Fuzzy, o qual tem uma abordagem matemática que analisa valores de entrada analógicos em termos de variáveis lógicas que assumem valores contínuos entre 0 e 1. Estes sistemas tiveram início no Japão onde cresceram e tiveram suas aplicações tanto da indústria quanto no setor de consumo.

No problema de UC os sistemas Fuzzy tiveram sua aplicação em método para analisar o efeito da incerteza de carga sobre o risco de UC, que é a probabilidade de ter capacidade de comprometimento insuficiente para compensar falhas de unidade e/ou variação imprevista de carga, esse método permite uma descrição qualitativa do comportamento de um sistema, sua característica e a resposta sem a necessidade de formulações matemáticas (PADHY, 2004).

2.2.4 Método utilizando Otimização de Enxame de Partículas

O algoritmo de Otimização de Enxame de Partículas ou *Particle Swarm Optimization* (PSO) é uma técnica de busca paralela com características de alto desempenho e facilidade de implementação (LEE; CHEN, 2007). Originalmente proposto por Kennedy e Eberhart em 1995 o método é baseado em população, onde cada partícula se move no espaço de busca com uma velocidade de acordo com sua melhor solução anterior e a melhor solução anterior de seu grupo (NEYESTANI; FARSANGI; NEZAMABADI-POUR, 2010).

No problema de UC, a PSO binária ou BPSO é utilizada para otimizar os estados ligado e desligado das unidades geradoras de energia. O PSO tem sido amplamente utilizado tendo as seguintes abordagens em destaque: Algoritmo de Otimização de Enxame de Partículas Aprimorado ou *Improved Particle Swarm Optimization Algorithm* (IPSO) (ZHAO

et al., 2006); Otimização de Enxame de Partículas Mutadas ou *Mutated Particle Swarm Optimization Algorithm* (MPSO) (KUO; LEE; SHEIM, 2011); Otimização de Enxame de Partículas Binárias com inspiração Quântica ou *namely quantum-inspired BPSO* (QBPOS) (JEONG et al., 2010).

2.2.5 Método utilizando Recozimento Simulado

O algoritmo de Recozimento Simulado ou *Simulated Annealing* (SA) é uma técnica probabilística que busca aproximar seu resultado do ótimo global de uma função. O SA baseia-se no processo físico de recristalização dos metais durante o processo de recozimento, começando com uma alta temperatura, um metal é resfriado lentamente, de modo que o sistema está em equilíbrio em todas as temperaturas e os átomos do sistema são ordenados e balanceados aleatoriamente, até que finalmente atinjam um estado de temperatura mínima próximo de zero, onde a energia do sistema adquiriu o valor mínimo local (VAN LAARHOVEN; AARTS, 1987).

O SA é um método iterativo que simula a evolução para o equilíbrio térmico de um metal para um valor fixo de temperatura. Em cada passo do algoritmo, um átomo é deslocado e ocorre a mudança na energia do sistema que é recalculada, se a perturbação resulta em uma energia menor do sistema, nesse caso, a mudança é aceita e a nova configuração do sistema constitui o ponto de partida para a próxima etapa e a probabilidade é dada pela distribuição de Boltzmann (SIMOPOULOS; KAVATZA; VOURNAS, 2006).

O SA é utilizado no problema de UC para encontrar o escalonamento ótimo das unidades geradoras durante o período de despacho. A configuração do sistema físico corresponde ao cronograma das unidades geradoras do problema de otimização. A energia dos átomos é análoga ao custo da função objetivo e a qualidade do fundo corresponde ao mínimo da função custo (SIMOPOULOS; KAVATZA; VOURNAS, 2006). Além disso, a temperatura desempenha o papel do parâmetro de controle para o procedimento de otimização, assim, as características mais importantes da técnica são: a seleção do valor inicial da temperatura, o número de iterações realizadas em cada estágio, a velocidade da bobina de geração e o valor final da temperatura (SIMOPOULOS; KAVATZA; VOURNAS, 2006).

2.2.6 Método utilizando Algoritmo Evolucionário de inspiração Quântica

Os algoritmos evolutivos ou *Evolutionary Algorithms* (EA) são inspirados pelos processos de evolução natural. Possuem uma grande variedade de modelos computacionais que tem em comum o conceito de simulação da evolução das espécies utilizando operadores de seleção, mutação e reprodução que dependem do resultado do desempenho individual da espécie dentro de um ambiente (LINDEN, 2008).

As pesquisas sobre combinação de computação evolucionária e computação quântica começaram no final dos anos 90. A computação evolucionária de inspiração quântica é um ramo do estudo da computação evolucionária que emprega certos princípios da mecânica quântica, como superposição, interferência, incerteza, bits quânticos (Q-bits) e *quantum gates* (Q-gates), a partir desses conceitos foram desenvolvidos os Algoritmos Evolucionários de inspiração Quântica ou *Quantum-Inspired Evolutionary Algorithm* (QEA), que pode alcançar um equilíbrio entre a exploração do espaço da solução e também obter melhores soluções (LAU et al., 2009).

O QEA foi testado para solucionar problemas de UC de pequena e de larga escala respeitando todas as restrições propostas (LAU et al., 2009).

2.2.7 Método utilizando Evolução Diferencial

O algoritmo de evolução diferencial ou *Differential Evolution* (DE) é um algoritmo evolutivo que utiliza um método paralelo de busca direta, baseada em uma população. Esse método depende de três parâmetros cruciais de controle, o tamanho populacional NP, o fator de escala F e a taxa de *crossover* (CR) que podem influenciar significativamente o desempenho de otimização na qual o DE está atuando (QIN; HUANG; SUGANTHAN, 2008).

Esse método teve diversas aplicações no problema de UC, sendo utilizado na sua abordagem real, inteira e binária para diversas propostas de solução (DATTA; DUTTA, 2012).

2.2.8 Método utilizando Colônia Artificial de Abelha

O algoritmo de Colônia de Abelhas ou *Artificial Bee Colony* (ABC) é um dos mais recentes algoritmos definidos por Dervis Karabogaem 2005. O ABC simula o comportamento

de abelhas reais e é descrito para resolver problemas de otimização (KARABOGA, 2005).

O algoritmo define três tipos de abelhas na colônia, as operárias, as espectadoras e as escuteiras. As abelhas operárias escolhem a fonte de alimento com base na sua experiência passada, as abelhas espectadoras escolhem a fonte de alimento baseado na experiência das suas parceiras de colônia e as escuteiras escolhem aleatoriamente uma fonte de alimento (KARABOGA, 2005). A escolha da melhor fonte de alimento é repetida até serem satisfeitas as condições do critério de parada.

Para aplicação em UC teve sua abordagem binária para satisfazer as condições de ligado e desligado das unidades geradoras (CHANDRASEKARAN et al., 2013).

2.2.9 Método utilizando Algoritmo Vagalume.

O Algoritmo Vagalume ou Firefly (FF) foi desenvolvido pelo autor Xin-She Yang e foi baseado no comportamento idealizado das características de *flashing* dos vagalumes (CHANDRASEKARAN et al., 2012). Para simplificar, essas características podem ser idealizadas conforme três regras: primeiro todos os vagalumes são unissex, de modo que um vagalume é atraído por outros, independentemente de seu sexo; a segunda regra sugere que a atratividade é proporcional ao brilho do vagalume, portanto, para quaisquer dois vagalumes piscantes, o menos brilhante se moverá para o mais brilhante, ao se afastarem o brilho diminui e caso ninguém seja mais brilhante que um vagalume em particular, ele se move aleatoriamente; a terceira regra define que brilho ou intensidade de luz de um vagalume é afetado ou determinado pela função objetivo a ser otimizada (YANG, 2010).

No problema de UC o algoritmo FF, por ter uma abordagem de código real, também sofre algumas alterações para satisfazer a natureza binária do problema (CHANDRASEKARAN; SIMON; PADHY, 2013). O FF em testes e implementação teve qualidade de solução maior quando comparado com PSO e algoritmo genético (CHANDRASEKARAN; SIMON; PADHY, 2013).

2.2.10 Método Utilizando Algoritmo Genético

Os Algoritmos genéticos (AG) são técnicas de otimização global inspirada no estudo da genética. Essa técnica será detalhada na sessão 2.3. Eles podem ser implementados para a solução de problemas difíceis de otimização e oferecem grande flexibilidade de modelagem (DAMOUSIS; BAKIRTZIS; DOKOPOULOS, 2004). Várias abordagens de AG para o

problema de UC foram relatadas na literatura, sendo essas abordagens tanto com aplicação de um AG simples quanto em conjunto com outras técnicas.

Os estudos de viabilidade realizados nestes algoritmos demonstram grande potencial nas soluções obtidas dentre os métodos já utilizados. Nas suas aplicações destaca-se a proposta de um algoritmo de escalonamento de UC usando operadores de mutação específicos de domínio, o qual teve a robustez esperada quando comparado com um algoritmo de relaxamento lagrangeano (PADHY, 2004).

2.3 ALGORITMO GENÉTICO

Os algoritmos genéticos são modelos computacionais inspirados na evolução, baseados em diversas teorias genéticas, dentre as quais se destacam a teorias de Charles Darwin, que explica sobre a seleção natural e a de Gregor Mendel, em que estudos formularam as leis da hereditariedade. Sendo assim o AG é uma subclasse de algoritmos evolutivos que simulam a evolução da espécie, a sobrevivência do mais apto e o comportamento adaptativo (LINDEN, 2008). Esses algoritmos são técnicas heurísticas de otimização global popularizados por John Holland, nas quais os elementos do espaço de pesquisa são cadeias binárias ou matrizes de outros tipos elementares (WEISE, 2009).

No AG se trabalha com a ideia de criação de indivíduos e população que são submetidos a operadores genéticos de seleção, recombinação (*crossover*) e mutação (LINDEN, 2008). Os indivíduos representam as soluções do problema e são constituídos de um fenótipo que se refere a um conjunto de características que interage com o ambiente e o genótipo definidos por um conjunto de propriedades chamado cromossomos. Em modelos mais simples o cromossomo e o individuo são uma *string* que representam a possível solução. A população é constituída por um conjunto de possíveis soluções, ou seja, um conjunto de indivíduos.

Os operadores que agem sobre os indivíduos utilizam a qualidade do individuo como solução dada pela função de avaliação (*fitness*) e geram um processo de evolução deste individuo que pode gerar uma melhor solução (WEISE, 2009). Para chegar à evolução do individuo o algoritmo genético segue uma sequência de procedimentos iniciados pelo processo de inicialização da população, seguida pela avaliação da população, com base nesta avaliação é feita a seleção dos pais para gerar novos indivíduos. Desta maneira são aplicados nos pais os operadores de *crossover* e mutação para gerar um individuo que combine as características dos pais (LINDEN, 2008). Os novos indivíduos gerados formam uma nova

população que substitui a anterior. Esse procedimento é repetido até se obter a melhor solução possível dentro dos limites do critério de parada que pode ser o número de gerações ou tempo de execução.

2.3.1 Inicialização

Para inicializar um algoritmo genético é necessário determinar o tamanho da população que depende da natureza do problema. E também é de grande importância escolher o método com que será gerada a população inicial, sendo que na maioria das aplicações é escolhido um método aleatório por gerar uma boa distribuição das soluções no espaço de busca (MITCHELL, 1999).

2.3.2 Função de Avaliação

A função de avaliação define parâmetros de aptidão de um indivíduo em um determinado ambiente, obtendo como resultado se o indivíduo é apto ou não a sobreviver, ou seja, ela calcula um valor numérico de acordo com os dados armazenados no cromossomo o que difere as boas das más soluções de acordo com o valor encontrado (LINDEN, 2008). Em muitos casos a função *fitness* é a única ligação com o problema real.

2.3.3 Seleção

A seleção é responsável por selecionar os indivíduos na população para reprodução (MITCHELL, 1999). Esse operador pode simular o processo de seleção natural no qual os pais mais aptos geram mais filhos e os pais menos aptos também geram filhos, mas em menor quantidade. Dentre as técnicas de seleção destacam-se as seguintes:

- Truncamento: no método de truncamento os melhores indivíduos são selecionados e o restante é descartado;
- Torneio: neste método são criados subconjuntos temporários nos quais são selecionados os melhores indivíduos.

- **Roleta:** neste método cada indivíduo da população é representado na roleta proporcionalmente ao seu índice de aptidão. Desta forma, para indivíduos com alta aptidão é dada uma porção maior da roleta, enquanto aos indivíduos de menor aptidão, é dada uma porção relativamente menor.
- **Ranking:** neste tipo de seleção a probabilidade de um indivíduo ser selecionado é proporcional à sua posição (classificação) na lista ordenada de todos os indivíduos da população.

2.3.4 Operadores genéticos

Os dois operadores fundamentais em algoritmos genéticos são o *crossover* e a mutação, descritos a seguir.

2.3.4.1 *Crossover*

O *crossover*, também chamado de recombinação, é um operador usado para combinar a informação genética de dois indivíduos para gerar novos descendentes (LINDEN, 2008). É uma maneira de gerar novas soluções a partir de uma população existente e é análoga ao cruzamento que acontece durante a reprodução sexual na biologia (MITCHELL, 1999). Entre os métodos de *crossover* estão os seguintes:

- *Crossover* de ponto único: um ponto nos cromossomos de ambos os pais é escolhido e designado como um ponto de cruzamento. Os bits à direita desse ponto são trocados entre os dois cromossomos. Isso resulta em dois filhos, cada um carregando algumas informações genéticas dos pais.
- *Crossover* de múltiplos pontos: dois pontos nos cromossomos de ambos os pais são escolhidos como pontos de cruzamento. O primeiro descendente é gerado com as partes de fora dos pontos de cruzamento do primeiro pai e as partes de entre os pontos de cruzamento do segundo pai.
- *Crossover* uniforme: Cada bit do genoma da descendência é escolhido de forma independente entre os dois pais. O *crossover* uniforme troca *bit* a *bit* ao contrário dos outros métodos que trocam segmentos de bits.

2.3.4.2 Mutação

A mutação é o operador responsável por manter a diversidade da população. A mutação realiza a alteração de um ou mais valores genéticos em um cromossomo de acordo com uma probabilidade pré-estabelecida, que normalmente tem um valor pequeno associado (WEISE, 2009). A mutação é aplicada de diferentes formas para diferentes tipos de representação de genoma, entre elas estão as seguintes:

- *Gaussiana*: esse operador adiciona um valor aleatório distribuído gaussiano unitário ao gene escolhido. Se estiver fora dos limites inferiores ou superiores especificados, o valor do gene é alterado. Este operador de mutação é utilizado para genes inteiros e de pontos flutuantes.
- *Flip*: esse operador substitui o valor do gene escolhido pelo seu valor inverso. Este operador de mutação é utilizado para genes binários.
- *Uniforme*: esse operador substitui o valor do gene escolhido por um valor aleatório uniforme selecionado entre os limites superior e inferior especificados pelo usuário para aquele gene. Este operador de mutação é utilizado para genes inteiros e de pontos flutuantes.

3 METODOLOGIA

3.1 SISTEMA

O sistema no qual será realizado o controle das unidades geradoras e a otimização do custo de produção de energia é organizado em 3 níveis, o primeiro nível (L1) é o nível físico, o qual é composto pelas unidades geradoras; o segundo nível (L2) é composto pelas microrredes e o terceiro (L3) é composto pela base de dados e a interface de controle. A Figura 1 ilustra essa arquitetura.

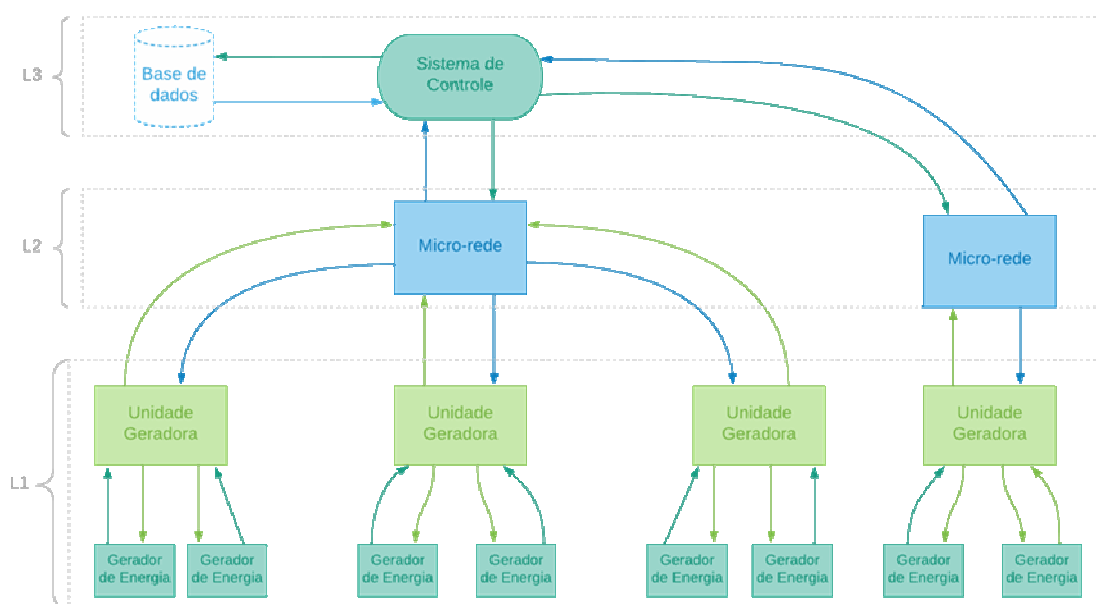


Figura 1 – Modelo de controle e comunicação do sistema de geração de energia
Fonte: a autora.

O L1 é composto por diversos geradores de energia que possuem características como: limitação de geração mínima e máxima, tempos mínimos em que a unidade pode permanecer ligada ou desligada e custo de produção. Essas informações são enviadas às unidades geradoras que definem a capacidade de geração local, tomando ações de controle independentes para manutenção dos recursos locais. As unidades geradoras informam ao sistema de controle seu estado de funcionamento, seus recursos disponíveis, assim como seu custo operacional e sua capacidade de reserva, se existente.

O L2, chamado de microrrede, consiste em uma rede de distribuição de energia responsável por distribuir a energia produzida pelos geradores de energia de acordo com parâmetros recebidos através de uma rede de comunicação com o sistema de controle.

Essa microrrede também informa seu estado de funcionamento para o sistema de controle assim como também informa sua capacidade de distribuição.

O L3 é responsável pelo controle inteligente que delega aos geradores a quantidade necessária a ser produzida de acordo com a demanda e as informações contidas na base de dados sobre os geradores de energia e as microrredes, com objetivo de obter o melhor cenário de geração de energia com melhor custo benefício.

Dentro dessa arquitetura, este trabalho aborda o problema de UC propondo um algoritmo de otimização na produção de energia das unidades geradoras, determinando quais devem produzir energia e qual magnitude. Esse algoritmo se encontra na camada L3 compondo o sistema de controle.

3.2 FORMULAÇÃO DO PROBLEMA DE UC

O objetivo do problema da UC é a minimização dos custos totais de produção ao longo do horizonte de programação. Portanto, a função objetivo é expressa como a soma dos custos de combustível e inicialização das unidades geradoras. Para unidades geradores de qualquer fonte se generaliza a definição matemática do custo de operação em uma hora, conforme mostrado a seguir (LAU et al.,2009).

$$CTP_n = \sum_{i=1}^N [FC + ST_i(1 - U_i)U_i] \quad (1)$$

O custo operacional acumula-se sobre o número total de horas de operação, onde $H = 24$, o que representa 24 horas de operação para cada unidade geradora. Portanto, (1) é reescrito como:

$$CTP_n = \sum_{h=1}^H \sum_{i=1}^N [FC + ST_i(1 - U_i)U_{ih}] \quad (2)$$

Em (1), CTP é o custo total de produção para unidades de geradores, enquanto CTP em (2) denota o custo total de produção de unidades geradoras sobre o número de horas de operação. Observação aos requisitos operacionais, à minimização da função objetivo é sujeita às seguintes restrições:

- a. Restrição do saldo de energia

$$\sum_{i=1}^N P_{ih} U_{ih} = D_h \quad (3)$$

b. Restrição de Reserva

$$\sum_{i=1}^N P_{i(max)} U_{ih} = D_h + R_h \quad (4)$$

c. Restrição de limite de geração

$$P_{i(min)} \leq P_{ih} \leq P_{i(max)} \quad (5)$$

d. Restrição mínima de tempo de atividade

$$X_i^{on}(t) \geq ML_i \quad (6)$$

e. Restrição mínima de tempo de inatividade

$$X_i^{off}(t) \geq MD_i \quad (7)$$

As notações utilizadas são as seguintes:

C_{TP} Custo total de produção da geração de energia;

FC Função de custo de combustível da unidade de geração é comumente dada por um polinômio quadrático representado a seguir:

$$FC = aP_{ih}^2 + bP_{ih} + c \quad (8)$$

onde a, b e c são coeficientes de custo de combustível;

N Número de unidades geradoras;

H Número de horas do cronograma de geração de energia;

P_{ih} Potência de geração na unidade i e na hora h ;

ST_i Custo de arranque da unidade;

U_{ih} Estado ligado / desligado da unidade i na hora h ;

D_h Demanda de carga na hora h ;

R_h Reserva na hora h ;

$P_{i(min)}$ Limite mínimo de geração da unidade;

$P_{i(max)}$ Limite máximo de geração da unidade;

- ML_i Tempo mínimo de funcionamento da unidade;
 MD_i Tempo de inatividade mínimo da unidade;
 $X_i^{on}(t)$ Duração a qual a unidade permanece ligada;
 $X_i^{off}(t)$ Duração a qual a unidade permanece desligada.

3.3 ALGORITMO GENÉTICO APLICADO AO PROBLEMA DE UC

3.3.1 Inicialização

Aplicando AG ao problema de UC, um alfabeto binário simples foi escolhido para codificar uma solução com a suposição que em cada hora uma unidade pode ser ligada ou desligada. Se N representa o número de unidades e H o período de programação em horas, um cromossomo de $N \times H$ bits é formado como ilustra a Figura 2.




Figura 2 - Representação de um cromossomo
 Fonte: a autora

Para a inicialização da população escolheu-se o método aleatório, com uma população inicial de 50 indivíduos. Os indivíduos são constituídos por um cromossomo, um custo total de produção, uma lista das unidades geradoras e suas informações como custo de arranque, potência máxima de geração, potência mínima, *status* inicial de funcionamento e coeficientes de custo de combustível. Além disso, cada indivíduo possui a potência gerada em cada hora por cada unidade geradora e um parâmetro de avaliação.

A potência gerada em cada hora do cronograma de funcionamento foi inicializada com um valor aleatório entre o limite de potência máxima e mínima para respeitar a restrição de limite de geração. E o parâmetro de avaliação é definido pela função que avaliação calculada da seguinte forma:

$$F = CTP + \sum_{i=0}^{NC} PF_i \quad (9)$$

As notações utilizadas para essa solução são as seguintes:

F	Função de avaliação;
CTP	Custo total de produção da geração de energia;
NC	Número de restrições operacionais violadas;
PF_i	Penalidade associada à restrição violada i definida como:

$$PF_i = \mu_i * |V_i| \quad (10)$$

Onde μ_i representa o peso da penalidade associada à restrição i . Esse peso, normalmente, é escolhido com um valor alto para desencorajar a escolha de indivíduos que descumpriram as restrições e V_i , representa a quantidade de violação da restrição i .

3.3.2 Seleção

Com base nos resultados obtidos na função de avaliação é realizada a seleção, neste caso foram testados os métodos da roleta e torneio. Para o método da roleta a porcentagem de chances que um indivíduo tem de ser selecionado para reprodução é dada pela função 11, onde N é o tamanho da população.

$$P_{\%} = \sum_{i=1}^N \frac{1}{F} \quad (11)$$

E para o método do torneio foram utilizados grupos de tamanho variável, dado por um valor aleatório entre 10% e 50% da população, este procedimento foi adotado para manter a diversidade das próximas gerações.

3.3.3 Operadores genéticos

Após a seleção foram testados os operadores *crossover* de um ponto, de múltiplos pontos e uniforme e a mutação do tipo *flip*. Esses operadores foram escolhidos por se adequarem ao problema de UC e a abordagem escolhida.

Para melhorar o desempenho desse algoritmo foram explorados outros operadores genéticos:

- **Elitismo:** é aplicado aos melhores indivíduos de cada geração possibilitando que as duas melhores soluções sejam copiadas para a próxima geração na tentativa de ampliar sua probabilidade de cruzamento e facilitar que suas características sejam herdadas por gerações futuras;
- *Swap-window operator* ou operador de janela de troca: é aplicado a todos os genótipos da população com uma probabilidade de 1% para este caso. Selecionando duas unidades geradoras e uma “janela de tempo” aleatoriamente. Essa janela de tempo é definida por dois pontos de corte $c1$ e $c2$ gerados aleatoriamente, onde a janela está entre $c1$ e $c2$. Então os bits das unidades gerados incluídos na janela são trocados. Esse operador age como um operador de mutação;
- *Swap-window hill-climb operator* ou operador de subida e descida de janela de troca: é aplicado apenas a melhor solução de cada geração, com uma probabilidade de 30% para este caso. Ele seleciona duas unidades geradoras arbitrárias $u1$, $u2$ e uma "janela de tempo" definida por um corte $c1$. A janela de tempo é primeiramente alinhada com a primeira hora do período de programação e se estende até o bit de corte, então os bits das duas unidades incluídos na janela são trocados. É realizada uma nova avaliação ao indivíduo, se a nova solução for melhor será mantida, caso contrário é restaurado o cromossomo inicial. Em seguida, a janela é deslocada em uma hora e é repetido o deslocamento até a janela atingir a última hora do período de programação. Esse operador realiza uma otimização de escalada local em relação ao comprometimento de duas unidades geradoras.

4 RESULTADOS

O algoritmo genético implementado tem o objetivo de minimizar a função de custo total do funcionamento das unidades geradas em um período de tempo pré-estabelecido de geração, tendo como resposta o cronograma de funcionamento das unidades geradoras e o custo total.

Para realização deste trabalho foi escolhida a linguagem Python. A Linguagem Python é uma linguagem de programação multiplataforma, orientada a objetos que permite integrar diversos serviços e sistemas e conta com diversas bibliotecas que auxiliam na manipulação de dados. Dentre essas bibliotecas, foram utilizadas a biblioteca *pandas* para manipulação de dados externos e a biblioteca *matplotlib* para geração dos gráficos dos resultados obtidos no AG.

Para realizar os testes dos algoritmos foram feitas 20 execuções utilizando uma população de 50 indivíduos com 500 gerações. Os dados utilizados para simular as unidades geradoras estão descritos na Tabela 1.

Tabela 1 - Dados das Unidades Geradoras

	Unidade 1	Unidade 2	Unidade 3	Unidade 4	Unidade 5
$P_{1\text{min}}$	455	130	130	80	55
$P_{1\text{max}}$	150	20	20	20	55
A	1000	700	680	370	660
B	16.19	16.60	16.50	22.26	25.92
C	0.00048	0.002	0.00211	0.00712	0.00413
ML_i	8	5	5	3	1
MD_i	8	5	5	3	1
ST_{quente}	4500	550	560	170	30
ST_{Frio}	9000	1100	1120	340	60
STh_{Frio}	5	4	4	2	0
SI	8	-5	-5	-3	-1

Fonte: Kazarlis, Bakirtzis e Petridis (1996, p. 86).

Onde SI representa o *status* inicial em horas de funcionamento, se positivo, indica o número de horas que a unidade já está funcionando e se negativo, indica o número de horas que a unidade já esteve inativa.

O ST_{quente} e o ST_{Frio} indicam o custo de arranque a quente ou a frio que substituem o valor de ST_i na função de custo total de produção. Esse custo é determinado pela STh_{Frio} que indica o número de horas em que o custo a frio é considerado, caso o número de horas de funcionamento seja superior ao STh_{Frio} o ST_{quente} é utilizado.

Outros parâmetros definidos em projeto, foram à taxa de mutação utilizada com 1% em cada bit do cromossomo gerado, este valor foi obtido de maneira experimental e baseado na literatura sobre AGs. As penalidades associadas à função de avaliação receberam o μ definido experimentalmente testando os valores de 1000, 10000, 100000, 1000000, 10000000, 100000000, com a melhor resposta obtida quando utilizando o valor de 100000000. E λ , com incremento em um a cada penalidade associada à unidade geradora em questão. O cronograma tem duração de 24 horas, com demanda definida na Tabela 2 e taxa de reserva de geração de 10%. Para estes parâmetros e penalidades indicadas na sessão 3.2 uma resposta é considerada viável quando respeita a restrição de saldo de energia.

Tabela 2 - Demanda para o Cronograma de 24 horas

Hora	1	2	3	4	5	6	7	8	9	10	11	12
Demanda	400	450	480	500	530	550	580	600	620	650	680	700
Hora	13	14	15	16	17	18	19	20	21	22	23	24
Demanda	650	620	600	550	500	550	600	650	600	550	500	450

Fonte: Kazarlis, Bakirtzis e Petridis (1996, p. 86).

Para realizar os três primeiros testes foi utilizado o método de seleção por torneio e o *crossover* foi realizado de um único ponto, uniforme e de múltiplos pontos, nesta ordem. Para os testes de quatro a seis foi utilizado o método de seleção roleta e o *crossover*, de um único ponto, uniforme e o de múltiplos pontos. Os dados obtidos nestes testes estão dispostos na Tabela 3 e 4.

Tabela 3 - Resultados teste de 1 a 3

	<i>Teste 1</i>	<i>Teste 2</i>	<i>Teste 3</i>
Método de seleção	Torneio	Torneio	Torneio
Crossover	Um ponto	Uniforme	Múltiplos pontos
F mínimo	8,200000998 e^{17}	8,000000816 e^{17}	7,000000951 e^{17}
F máximo	11,12000010 e^{17}	10,60000125 e^{17}	10,70000103 e^{17}
Varição de F	3,000000041	2,600000437	3,700000081
CTP mínimo	3568879558,96	2426854940,73	2443584423,88
Acertos	14	14	15

Fonte: a autora

Tabela 4 - Resultados teste de 4 a 6

	<i>Teste 4</i>	<i>Teste 5</i>	<i>Teste 6</i>
Método de seleção	Roleta	Roleta	Roleta
Crossover	Um ponto	Uniforme	Múltiplos pontos
F mínimo	15,50000117 e^{18}	1,610000121 e^{18}	1,5300001011 e^{18}

F máximo	2,120000113 e ¹⁸	2,010000111 e ¹⁸	2,0000001197 e ¹⁸
Varição de F	0,569999996	0,399999999	0,470000019
CTP mínimo	1941237728,34	2384143324,31	2247237561,10
Acertos	9	12	11

Fonte: a autora

Os valores de F mínimo representam o menor valor encontrado nas 20 execuções para a função de avaliação e o F máximo representa o maior valor. A variação de F representa a diferença entre o maior e menor valor encontrado nas 20 execuções sendo a variação da resposta encontrada, o CTP mínimo representa o custo total de operação encontrado quando a função de avaliação possui o menor valor. Os acertos são referentes ao número de horas em que a melhor resposta cumpriu a demanda mínima de geração, para este problema é o fator de maior importância.

Com esses testes foi possível observar que a utilização do método de seleção da roleta gera uma variação menor na resposta, enquanto o número de acertos é maior no método de seleção por torneio. Como esses testes visavam encontrar a menor variação entre as respostas encontradas nas 20 execuções foram selecionados os métodos empregados na Tabela 4.

Os próximos testes visavam uma melhoria nas respostas encontradas para isso foram utilizados operadores adicionados aos métodos da Tabela 4. Esses operadores genéticos são o *Swap-window operator*, *Elitismo* e *Swap-window hill-climb operator*. E para melhorar a resposta em relação à demanda mínima, também foi adicionada uma avaliação da demanda mínima ao AG que é aplicada no processo de criação da população. Quando o indivíduo descumpra essa restrição é feito o sorteio de uma das unidades geradoras e sua potência de geração é alterada para potência máxima. Se essa modificação foi o suficiente para alcançar a demanda mínima a avaliação segue para a próxima hora, se não o processo de sorteio e a alteração da potência são realizados novamente até atingir o número de unidades geradoras, então os sorteios são cessados.

Os dados encontrados para os testes 7, 8 e 9 estão dispostos na Tabela 5.

Tabela 5 - Resultados teste de 7 a 9

	Teste 7	Teste 8	Teste 9
Método de seleção	Roleta	Roleta	Roleta
Crossover	Um ponto	Uniforme	Múltiplos pontos
F mínimo	2,100000013 e ¹⁸	2,100000012 e ¹⁸	2,310000008 e ¹⁸
F máximo	2,530000009 e ¹⁸	2,530000011 e ¹⁸	2,530000009 e ¹⁸

Variação de F	0,429999879	0,429999999	0,190000081
CTP mínimo	3450851957,33	3680604799,98	3472039104,88
Acertos	21	24	21

Fonte: a autora

Os testes de 7 a 9 mostram que o algoritmo com o acréscimo dos operadores possui melhor adequação a restrição de demanda e variação da resposta aceitável. O teste que mais se adequou ao problema, cumprindo todas as restrições de demanda mínima foi o teste 8. Nesse teste foram realizado os seguintes passos:

1. Inicialização da população aleatória
2. Avaliação da população pela função F
3. Ordenação da população em ordem crescente
4. Escolha do melhor indivíduo dessa geração, indivíduo com menor valor de F
5. Escolha dos pais pelo método da roleta
6. *Crossover* uniforme
7. Mutação
8. *Swap-window operator*
9. Elitismo
10. Avaliação da demanda
11. Ordenação da nova população
12. Substituição da população antiga pela nova
13. *Swap-window hill-climb operator*
14. Escolha do melhor indivíduo
15. Se o critério de parada for alcançado retorna o melhor indivíduo, se não retorna ao passo 5.

Neste caso o resultado obtido como melhor indivíduo possui as características apresentadas na Tabelas 6 e 7

Tabela 6 - Potências geradas em cada unidade por hora

Unidades	Potência por hora
Unidade 1	286, 411, 455.0, 448, 331, 262, 313, 264, 455.0, 455.0, 455.0, 455.0, 255, 308, 315, 391, 447, 455.0, 455.0, 383, 275, 206, 156, 385
Unidade 2	80, 81, 125, 115, 0, 40, 85, 113, 71, 24, 130.0, 130.0, 130.0, 60, 127, 58, 87, 85, 74, 24, 130.0, 123, 101, 99
Unidade 3	25, 96, 26, 54, 82, 130.0, 124, 108, 130.0, 115, 26, 130.0, 130.0, 127, 93, 85, 65, 89, 28, 130.0, 130.0, 86, 130.0, 44
Unidade 4	0, 26, 80.0, 42, 62, 80.0, 54, 80.0, 39, 74, 80.0, 80.0, 80.0, 75, 55, 35, 27, 46, 38, 58, 25, 80.0, 59, 24
Unidade 5	55, 55, 55.0, 55, 55, 55, 55, 55, 55, 0, 55.0, 0, 55.0, 55, 55, 55, 55, 55, 55.0, 55, 55, 55, 55

Fonte: a autora

Tabela 7 - Potências totais geradas por hora

Hora	0	1	2	3	4	5	6	7	8	9	10	11
$f_{i,h}^p$	446	669	741	714	530	567	631	620	750	668	746	795
Hora	12	13	14	15	16	17	18	19	20	21	22	23
$f_{i,h}^p$	650	625	645	624	681	730	650	650	615	550	501	607

Fonte: a autora

Cromossomo:

```
[[1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1],
 [1, 1, 1, 1, 0, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1],
 [1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1],
 [0, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1],
 [1, 1, 1, 1, 1, 1, 1, 1, 1, 0, 1, 0, 1, 1, 1, 1, 1, 1, 1, 1, 1, 1]]
```

A partir do cromossomo e das potências geradas é possível observar o descumprimento do tempo de inatividade mínimo das unidades 2 e 4 e o cumprimento das demais restrições. As Figuras 3 e 4 ilustram a evolução do melhor indivíduo de cada geração tanto da função de avaliação quanto da função de custo total. Essas figuras indicam que a função de avaliação inicialmente tem seu valor aumentado para satisfazer as restrições de demanda e depois conforme as gerações evoluem oscila para que possa abranger um maior espaço de busca, tendo mais chances de encontrar uma solução viável.

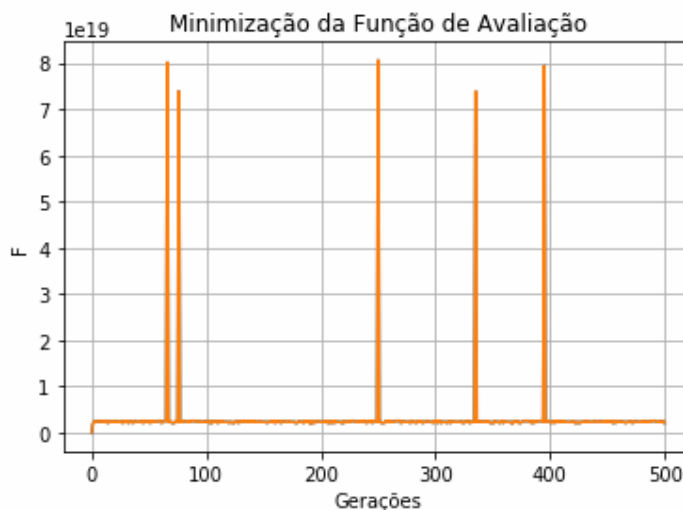


Figura 3 – Evolução da função de avaliação

Fonte: a autora

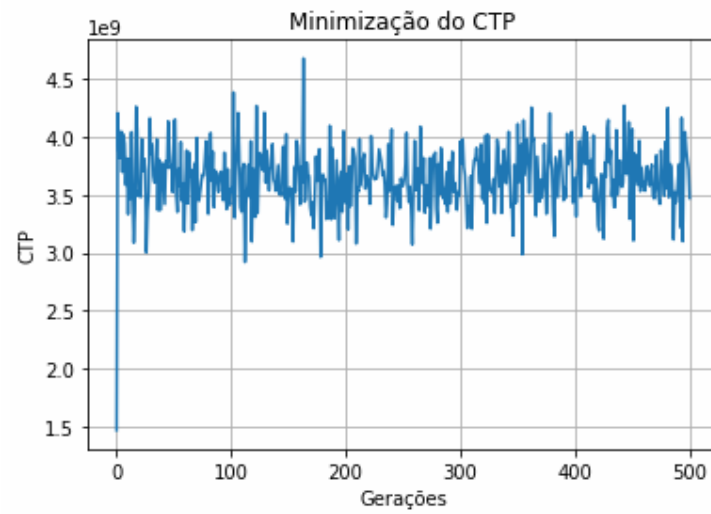


Figura 4 - Evolução da função de custo total
Fonte: a autora

Essas oscilações ocorrem principalmente por conta dos operadores de troca de janela, que fazem com que os bits de duas unidades geradoras sejam trocados em um determinado período o que gera uma diversidade na população evitando que a função fique em um mínimo local.

5 CONCLUSÃO

A análise da geração de energia distribuída e do gradual aumento de fontes de energia renovável nas matrizes energéticas indica que métodos que possam controlar e garantir a confiabilidade da geração, de maneira genérica devem ser levados em consideração. O problema de UC neste contexto possui diversas abordagens estocásticas propostas pela literatura, devido ao fato de possibilitar a aproximação da solução ideal em um tempo de computação realista. A aplicação dessa otimização aos controles que têm sido empregados no sistema de energia possibilitaria uma economia considerável de recursos.

Uma solução de Algoritmo Genético simples foi proposta neste trabalho, a qual teve que ser melhorada com a adição de novos operadores específicos para o problema, a fim de obter soluções de comprometimento de unidade satisfatórias. Uma vantagem básica da solução AG é a flexibilidade que ela oferece na modelagem de restrições. Outra vantagem é que os AGs podem ser convertidos para funcionar em computadores paralelos melhorando o seu tempo de execução. Uma desvantagem deste método é que, como eles são algoritmos de otimização estocástica, o aperfeiçoamento da solução que eles fornecem não pode ser garantido.

Para trabalhos futuros seria de grande importância o desenvolvimento de um sistema que integrasse o método de otimização às unidades geradoras e disponibilizasse os dados para o seu monitoramento de maneira clara. E também seria válido o estudo aprofundado de métodos híbridos por terem grande recorrência na literatura.

6 REFERÊNCIAS

- ABRAPCH. **Participação de renováveis na matriz energética brasileira é três vezes superior ao indicador mundial**, 2016. Disponível em: <<http://www.abrapch.org.br/noticias/1697/participacao-de-renovaveis-na-matriz-energetica-brasileira-e-tres-vezes-superior-ao-indicador-mundial>>. Acesso em: 12 jun. 2018.
- A.GOMEZ-EXPOSITO; A.J.CONEJO; CANIZARES, C. **Electric energy systems: analysis and operation**. Boca Raton: CRC Press, 2008.
- ANEEL. **Cadernos temáticos ANEEL micro e minigeração distribuída sistema de compensação de energia elétrica**. 2 ed. Brasília: Agência Nacional de Energia Elétrica, 2016.
- ANEEL. **Atlas de energia elétrica do Brasil**. s.d. Disponível em: <http://www2.aneel.gov.br/arquivos/pdf/atlas_par2_cap4.pdf>. Acesso em: 8 jun. de 2018.
- ANEEL. **Saiba mais sobre o setor elétrico brasileiro**, s.d. Disponível em: <http://www.aneel.gov.br/home?p_p_id=101&p_p_lifecycle=0&p_p_state=maximized&p_p_mode=view&101strutsaction=%2Fassetpublisher%2Fviewcontent&101returnToFullPageURL=%2F&101assetEntryId=14476909&101type=content&101groupId=654800&101urlTitle=faq&inheritRedirect=true>. Acesso em: 10 jun. 2018.
- ARAUJO, C. S. et al. **Utilização de fasores no sistema interligado nacional**. In: VII SIMPASE. Rio de Janeiro, Brasil: [s.n.], 2009.
- Basheer I.A., Hajmeer M. **Artificial neural networks: fundamentals, computing, design, and application**. Journal of Microbiological Methods, v. 43, p. 3-31, 2000.
- BERTSIMAS, D. et al. **Adaptive robust optimization for the security constrained unit commitment problem**. IEEE Transactions on Power Systems, v. 28, p. 52–63, 2013.
- BOSE, B. **Expert system, fuzzy logic, and neural network applications in power electronics and motion control**. Proceedings of the IEEE, v. 82, p. 1303 – 1323, 1994.
- BRETTEL, M. et al. **How virtualization, decentralization and network building change the manufacturing landscape: an industry 4.0 perspective**. World Academy of Science, Engineering and Technology International Journal of Information and Communication Engineering, v. 8, p. 37–44, 2014.
- BROKER, H. E. M. **MQTT essentials part 2: publish & subscribe**. 2016. Disponível em: <<https://www.hivemq.com/blog/mqtt-essentials-part2-publish-subscribe>>. Acesso em: 8 mai. 2018.
- CHANDRASEKARAN, K. Thermal unit commitment using binary/real coded artificial bee colony algorithm. **Electric Power Systems Research**, v. 854, p. 109-119, 2012. Disponível

em:< <https://www.sciencedirect.com/science/article/pii/S0378779611002471>>. Acesso em: 5 out. 2018.

CARDOSO, S. Cimo. **Sustentável**: emissão de gases de efeito estufa em reservatórios de água para geração de energia elétrica. 2017. Disponível em: <<https://www.cimoambiental.com.br/cimo-sustentavel-emissao-de-gases-de-efeito-estufa-em-reservatorios-de-agua-para-geracao-de-energia-elet>>. Acesso em: 12 jun. 2018.

DAMOUSIS, G.; BAKIRTZIS, A.G.; DOKOPOULOS P.S. **A solution to the unit-commitment problem using integer-coded genetic algorithm**. IEEE Transactions on Power Systems, v.19, p. 1165 -1172 , 2004. Disponível em: <<https://ieeexplore.ieee.org/abstract/document/1295029/authors#authors>>. Acesso em: 29 ago. 2018.

DATTA D.; DUTTA, S. **A binary-real-coded differential evolution for unit commitment problem**. Electrical Power and Energy Systems. Springer, Berlin, Heidelberg, v. 7080, p. 404-417, 2011. Disponível em:< https://link.springer.com/chapter/10.1007/978-3-642-25725-4_36#citeas >. Acesso em: 30 set. 2018.

ECO.A. **A energia que queremos**. 2016. Disponível em: <<http://ecoa.org.br/a-energia-que-queremos/>>. Acesso em: 17 abr. 2018.

ECYCLE. **O que é energia solar, vantagens e desvantagens**. s.d. Disponível em: <<https://www.ecycle.com.br/2890-energia-solar>>. Acesso em: 02 jun. 2018.

ENERGIA, P. **Vantagens e desvantagens da energia eólica**. 2015. Disponível em: <<https://www.portal-energia.com/vantagens-desvantagens-da-energia-eolica/>>. Acesso em: 02 jul. 2018.

ENERGY show. **Biomassa**. s.d. Disponível em: <<http://showenergy.com.br/biomassa/>>. Acesso em: 12 jun. 2018.

EPE. **Sistema de informações geográficas do setor energético brasileiro**. s.d. Disponível em: <<https://gisepeprd.epe.gov.br/webmapepe/>>. Acesso em: 30 mai. 2018.

INEE. **O que é geração distribuída**. s.d. Disponível em: <<http://www.aneel.gov.br/documents/656877/14854008/Boletim+de+Informa%C3%A7%C3%B5es+Gerenciais+-+4%C2%BA+trimestre+2017/44ee3035-27e5-0398-e7e3-c612ec4dc994>>. Acesso em: 27 mar. 2018

GERVEN, M.; BOHTE, S. **Artificial neural networks as models of neural information processing**. Frontiers in Computational Neuroscience, 2018.

JEONG, Y.W. et al. **A new quantum-inspired binary PSO: application to unit commitment problems for power systems**. IEEE Transactions on Power Systems, v. 25, p. 1486 – 1495, 2010.

- KARABOGA, D. **An idea based on honey bee swarm for numerical optimization**. 2005. Disponível em: <<https://pdfs.semanticscholar.org/015d/f4d97ed1f541752842c49d12e429a785460b.pdf>>. Acesso em: 08 out. 2018.
- KAZARLIS, S.; BAKIRTZIS, A.; V.PETRIDIS. A genetic algorithm solution to the unit commitment problem. **IEEE Transactions on Power Systems**, v. 11, p. 83–92, 1996.
- KUO C.C.; LEE C.Y; SHEIM, Y.C. Unit commitment with energy dispatch using a computationally efficient encoding structure. **Energy Conversion and Management** v. 52, p 1575-1582, 2011.
- LAU, T.W et al. Quantum-inspired evolutionary algorithm approach for unit commitment. **IEEE transactions on power system**, v 20, p. 1503-1512, 2009.
- LINDEN, R. **Algoritmos genéticos**, 2 ed, Rio de Janeiro: Braspor,2008.
- LISERRE, M.; SAUTER, T.; HUNG, J. Future energy systems: Integrating renewable energy sources into the smart power grid through industrial electronics. **IEEE Industrial Electronics Magazine**, v. 4, p. 18–37, 2010.
- LOPES, V. S.; BORGES, C. L. T. Impact of the combined integration of wind generation and small hydropower plants on the system reliability. **IEEE Transactions on Sustainable Energy**, v. 6, p. 1169–1177, 2015.
- MARTINS, F.; GUARNIERI, R.; PEREIRA, E. O aproveitamento da energia eólica. **Revista Brasileira de Ensino de Física**, v. 30, 2008.
- MASTERS, G. M. **Renewable and efficient electric power systems**. New Jersey: John Wiley e Sons, Inc., Hoboken, 2004.
- MITCHELL M. **An introduction to genetic algorithms**. A Bradford Book The MIT Press, 1999.
- MME. **Proinfra**. s.d. Disponível em: <<http://www.mme.gov.br/web/guest/aceso-a-informacao/acoes-e-programas/programas/proinfra;jsessionid=6303AAE5914FECA1F42844D315BBE50F.srv155>>. Acesso em: 28 mar. 2018.
- O' BRIEN, James A. **Sistemas de informação e as decisões gerenciais na era da internet**. São Paulo: Saraiva,2002. 437p.
- PADHY, N. Unit commitment: a bibliographical survey. **IEEE Transactions on Power System**, v. 19, p. 1196 – 1205, 2004.
- PAO, L.; JOHNSON, K. A tutorial on the dynamics and control of wind turbines and wind farms. **IEEE**, 2009.
- POZO, A. et al. **Computação evolutiva**. s.d. Disponível em: <<http://www.inf.ufpr.br/aurora/tutoriais/Ceapostila.pdf>>. Acesso em: 23 jun. 2018.

QIN, A.K.; HUANG V.L.; SUGANTHAN P.N. Differential evolution algorithm with strategy adaptation for global numerical optimization. **IEEE Transactions on Evolutionary Computation**, v.13, p. 398 – 417, 2009. Disponível em: <<https://ieeexplore.ieee.org/abstract/document/4632146/authors#authors> >. Acesso em: 30 set. 2018.

REIS, L. B. d. **Geração de energia elétrica**. 2. ed. São Paulo: Manole, 2011. 460 p. ISBN 9788520430392.

REN, W.; BEARD, R. W. Consensus seeking in multiagent systems under dynamically changing interaction topologies. **IEEE Transactions on Automatic Control**, v. 50, p. 655 – 661, 2005.

SCHALKOFF, R. J. **Redes Neurais Artificiais**. McGraw-Hill, 1997.

SIMOPOULOS D.N.; KAVATZA S.D.; VOURNAS C.D. Unit Commitment by an Enhanced Simulated Annealing Algorithm. **IEEE PES Power Systems Conference and Exposition**, 2006. Disponível em: <<https://ieeexplore.ieee.org/abstract/document/4075743> >. Acesso em: 18 set. 2018.

TING, T.O. ; RAO, M.V.C. ; LOO, C.K. A novel approach for unit commitment problem via an effective hybrid particle swarm optimization. **IEEE Transactions on Power Systems**, .v 21, p. 411 – 418, 2006. Disponível em: <<https://ieeexplore.ieee.org/document/1583740>>. Acesso em: 26 out. 2018.

TRIVEDI, A.; SRINIVASAN, D.; PAL, K. Enhanced multiobjective evolutionary algorithm based on decomposition for solving the unit commitment problem. **IEEE Transactions on Industrial Informatics**, v. 11, p. 1346 – 1357, 2015.

VAN LAARHOVEN, P.J.M.; E.H.L. AARTS. **Simulated Annealing: Theory and Applications**, v 37, p. 7-15 Disponível em: <https://link.springer.com/chapter/10.1007/978-94-015-7744-1_2 >. Acesso em: 20 set. 2018.

YANG, X.S. **Firefly algorithm, stochastic test functions and design optimisation**. Disponível em: <<https://arxiv.org/pdf/1003.1409.pdf>>. Acesso em: 17 jun. 2018

YUN-WON, J. et al. Future energy systems: Integrating renewable energy sources into the smart power grid through industrial electronics. **IEEE Transactions on Power Systems**, v. 25, p. 1486 – 1495, 2010.

ZOMER, C.; RUTHER, R. **Aplicação e avaliação de métodos de estimativa da influência do sombreamento parcial na geração energética de sistemas solares fotovoltaicos integrados a edificações**. In: VII Congresso Brasileiro de Energia Solar. Gramado, Brasil: [s.n.], 2018.