

# Otimização da Demanda de Potência contratada utilizando Algoritmos Genéticos

Thales B. C. de Azevedo\* Max C. P. Filho\*\*

\*Mestrado Profissional em Energia Elétrica, Universidade Federal do Rio Grande do Norte, RN,  
(e-mail: thales@infra.ufrn.br).

\*\*Departamento de Engenharia Elétrica, Universidade Federal do Rio Grande do Norte, Natal, RN,  
(e-mail: maxchianca@ct.ufrn.br)

---

**Abstract:** For consumers served by the voltage higher than 2,3 kV, belonging to the group A, the active power demand value to be contracted with power distribution company comes to be significant factor in the energy monthly bill. In moments that the resources are few, the great choice of this demand, as well as of the most useful tariff modality, it will must be done of such way that the power and energy demanded are available with no additional costs, and the value to be paid be as small as possible. This work shows a optimization purpose by the genetic algorithms, applied to the problem of the active power demand contraction, faced by the clients of group A, included in the blue horary tariff modality, where is necessary to be contracted a demand value at the peak hours and another value demand at the out of peak hours. Simulations were done and the results showed that the optimization model with genetic algorithms is a nice tool to the determine the optimal demand value to be contracted.

**Resumo:** Para os consumidores atendidos em tensão superior a 2,3 kV, pertencentes ao Grupo A, o valor da demanda de potência ativa a ser contratado com a concessionária de distribuição de energia elétrica passa a ter um peso significativo na fatura mensal. Em momentos em que os recursos são escassos, a escolha vantajosa dessa demanda, bem como da modalidade tarifária mais adequada, deverá ser feita de tal forma que a potência e a energia solicitadas estejam disponíveis sem custos adicionais, e o valor a ser pago seja o menor possível. Este trabalho apresenta uma proposta de otimização por meio de algoritmos genéticos, aplicada ao problema da contratação de demanda de potência ativa, encarado pelos clientes do Grupo A, enquadrados na modalidade tarifária horária azul, em que é necessário ser contratado um montante de demanda no posto horário de ponta e outro no posto horário fora de ponta. Simulações foram feitas e os resultados mostraram que o modelo de otimização com algoritmos genéticos é uma boa ferramenta para se determinar o valor ótimo de demanda a ser contratada.

**Keywords:** Optimization; contracted demand; genetics algorithms; cost savings; genetic code.

**Palavras-chaves:** Otimização; demanda contratada; algoritmos genéticos; redução de custos; código genético.

---

## 1. INTRODUÇÃO

Os consumidores de energia elétrica, de maneira geral, são classificados em dois grandes grupos, são eles: grupos A e B. Os consumidores dos grupos A são aqueles atendidos em tensão de fornecimento igual ou superior a 2,3 kV e caracterizados pela tarifa binômica de faturamento. Os consumidores do grupo B são aqueles atendidos em tensão de fornecimento inferior a 2,3 kV e caracterizados por tarifa monômica de faturamento.

Entende-se por tarifa binômica a modalidade tarifária caracterizada por tarifas de consumo de energia elétrica e de demanda de potência, independentemente das horas de utilização do dia. Já a tarifa monômica é a modalidade tarifária caracterizada por tarifas de consumo de energia elétrica apenas, independentemente das horas de utilização do dia.

## 2. CONTRATAÇÃO DE DEMANDA DE POTÊNCIA

Tomar a decisão de escolher uma demanda contratada sem nenhum critério, constitui um problema que pode acarretar grandes perdas, inclusive monetárias. Se a demanda contratada for alta, o consumidor pagará por um valor de demanda de potência que, por mais que lhe esteja disponível, ele não estará utilizando e não lhe será útil. Por outro lado, se a demanda contratada for demasiadamente baixa, o consumidor estará sujeito a cobranças por ultrapassagem desta demanda. A tarifa para cobrança por ultrapassagem se constitui em um valor duas vezes maior do que a tarifa pela demanda contratada.

Os trabalhos e pesquisas para a solução do problema da busca pela demanda ótima a ser contratada não são tão recentes. Os autores (CHEN e LIAO, 2011) foram praticamente os pioneiros a apresentar um método de busca pela demanda ótima utilizando algoritmos genéticos e em seguida por enxame de partículas. Eles incluíram dados de consumidores

de alta tensão que são cobrados por tarifas horárias (na ponta e fora de ponta). Seu trabalho teve o objetivo de buscar o valor de demanda ótima a ser contratada com o algoritmo sendo executado através de programação linear. Eles utilizaram dois estudos de caso, com dados fornecidos pelos clientes, e o programa encontrou a solução em um tempo menor que 0,001 minuto. O seu primeiro estudo de caso teve o objetivo de encontrar apenas a melhor demanda a ser contratada. E o segundo, quais seriam os melhores valores de demanda a ser contratada nos períodos de ponta e fora de ponta.

Desta maneira, o consumidor precisa estabelecer uma estratégia para que suas demandas contratadas sejam otimizadas. Pois se a demanda estiver sobrecontratada, haverá desperdício para este consumidor que pagará por um montante de potência que não foi consumida. Já se, a demanda for subcontratada, ocorrerá a cobrança de altos valores de multas por ultrapassagem. Percebe-se então que, em ambos os casos, acontecerá desperdício de energia, daí vem a importância de se escolher a demanda contratada de forma ótima, a fim de que os custos com essa parcela sejam os menores possíveis.

O trabalho de (ALBUQUERQUE, 2015) propõe uma otimização robusta aplicada à contratação de energia elétrica considerando a incerteza na demanda futura. Foram apresentados alguns cenários sob critérios de linearidade, variância e tendência das curvas. Seus resultados mostraram que o modelo heurístico utilizado com a otimização robusta foi melhor que o modelo determinístico. Sua conclusão é que a otimização robusta admite que o modelo tenha incertezas, seus resultados sejam experimentados, principalmente, com relação à demanda contratada, que é um dilema enfrentado por consumidores de alta tensão diante de situações de incertezas.

Os autores (PACHECO e ROCHA, 2001) também propuseram uma otimização nos contratos de demanda utilizando algoritmos genéticos. Posteriormente, em outro trabalho, eles aplicaram o AG também em tarifas do mercado livre de energia elétrica. Por conta disso, seu trabalho passou a fazer parte do Projeto de Pesquisa e Desenvolvimento em Eficiência Energética da concessionária Light Serviços de Eletricidade S.A. Esse trabalho utilizou algoritmos genéticos para determinar o melhor enquadramento tarifário (se convencional ou horossazonal) para consumidores do grupo A. Como resultado, foi verificado em suas simulações que, sem elitismo, que é uma das etapas do algoritmo genético, o algoritmo não conseguia encontrar o valor ótimo para o problema dentro de um limite de 40 gerações. Já quando se aplicava o elitismo, o algoritmo convergia para a solução ótima com uma melhor rapidez, em menos de 15 gerações.

O trabalho de (OZUR; PEREIRA; CORREA, 2011) abordou um Sistema de Gerenciamento do Consumo e da Qualidade de Energia Elétrica sob a ótica do gerenciamento da curva de carga de consumidores industriais através de controladores programáveis, que são dispositivos que monitoram o valor de demanda contratada e alertam quando a carga da indústria está próximo de atingir este valor. Uma desvantagem a ser observada em seu trabalho é que este tipo de monitoramento não leva em consideração se a demanda é ótima ou não, apenas se preocupa se a mesma será ultrapassada, a fim de evitar gastos com valores de ultrapassagem. Entretanto, destaca-se

como vantagem, o fato de encarar os gastos com ultrapassagem de demanda como uma oportunidade de negócio, ou seja, o montante gasto com ultrapassagem poderia ser aproveitado para outros benefícios, como por exemplo, investimentos em manutenção. O resultado traz como conclusão, o argumento de que o gerenciamento de energia é importante tanto nos momentos em que o aumento da demanda se faz necessário, como nos momentos de diminuição. Em períodos onde a produção precisa ser acelerada para atender determinados pedidos, a ultrapassagem intencional da demanda contratada é justificada nestes casos. E a diminuição da demanda contratada pode ser considerada priorizando determinadas cargas a serem ligadas e outras a serem desligadas em períodos programados.

Tomar a decisão de escolher uma demanda contratada sem nenhum critério, constitui um problema que pode acarretar grandes perdas, inclusive monetárias. Se a demanda contratada for alta, o consumidor pagará por um valor de demanda de potência que, por mais que lhe esteja disponível, ele não estará utilizando e não lhe será útil. Por outro lado, se a demanda contratada for demasiadamente baixa, o consumidor estará sujeito a cobranças por ultrapassagem desta demanda. A tarifa para cobrança por ultrapassagem se constitui em um valor duas vezes maior do que a tarifa pela demanda contratada. As consequências são as perdas de competitividade, pois, no caso de uma indústria, o produto final poderá ficar mais caro. Já os prejuízos para a concessionária são que ela teve de investir em infraestrutura e em sua capacidade de fornecimento para um determinado consumidor que não gerencia bem seu consumo.

### 3. ALGORITMOS GENÉTICOS

Dentre os diversos mecanismos de otimização e busca existentes, os algoritmos genéticos, AG's, são aqueles inspirados na teoria biológica da evolução dos seres vivos. Foi John Holland, cientista norte-americano, que introduziu a teoria dos algoritmos genéticos. Porém, foi popularizado por um de seus alunos, David Goldberg. Baseia-se então, na teoria da seleção natural, em que os indivíduos mais aptos são aqueles que conseguem sobreviver e gerar descendentes.

O princípio básico dos AG's é levar em conta que as diversas soluções de um dado problema são considerados como indivíduos de uma população, onde eles serão avaliados, e as melhores soluções (indivíduos mais aptos) terão maiores chances de serem escolhidos, se reproduzirem e, na iteração seguinte (nova população), os indivíduos se apresentarão mais evoluídos do que os da geração passada.

Esta é a técnica utilizada no desenvolvimento deste trabalho. Os algoritmos genéticos. Ele é utilizado para buscar a melhor solução para o problema da demanda de potência ativa contratada por um consumidor enquadrado na modalidade tarifária horária azul, que para este trabalho foi utilizado os dados de demanda da Universidade Federal do Rio Grande do Norte. Um fluxograma que representa um modelo básico de algoritmo genético é mostrado na Figura 1.

Figura 1: Estrutura Básica de um AG



FONTE: Medeiros, 2017

Figura 2: Estrutura utilizada na aplicação do método



FONTE: Adaptado de Saccaro e Corso, 2019

#### 4. APLICAÇÃO DO MÉTODO

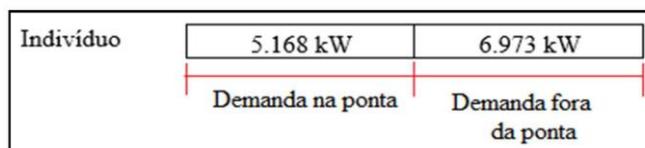
O algoritmo foi simulado no ambiente *Scilab*, distribuído de forma gratuita e utilizado em vários ambientes industriais e educacionais. Os AG's se constituem em um método de busca estocástico, que por ser baseado nas teorias evolucionárias da biologia, tenta solucionar problemas de otimização, compreendendo um conjunto de indivíduos, que é a população. Em termos computacionais, o algoritmo genético buscará a melhor solução para um problema em um conjunto de dados, selecionando os dados mais interessantes para a solução desejada.

O método utilizado neste trabalho, que é o de otimizar os custos referentes a demanda de potência ativa contratada, juntamente com a implementação do algoritmo genético, é mostrado na Figura 2.

##### 4.1 Indivíduo e Características Gerais

No algoritmo genético, normalmente, o indivíduo é a parte mais importante do processo. Pois ele traz consigo as informações que serão analisadas e passarão pelo processo de evolução, otimizando assim esta solução. Neste trabalho, o indivíduo é composto de duas partes básicas, a demanda na ponta e a demanda fora de ponta. Seus valores é que determinam o seu desempenho, a Figura 3 traz uma representação básica do indivíduo neste trabalho.

Figura 3: Exemplo de Indivíduo



FONTE: Elaboração própria

O cálculo dos custos foi necessário para avaliar o desempenho (*fitness*) de cada indivíduo, e o algoritmo genético, buscará a melhor solução, ou seja, o melhor indivíduo. Como o objetivo é de minimizar os custos com as demandas contratadas, então a melhor solução será aquela que irá gerar os menores custos possíveis.

Para executar o processamento, é necessário que o usuário informe:

- Valores de demanda dentro de uma faixa aceitável, normalmente dentro dos limites entre a demanda máxima e mínima para um período a ser analisado, em kW;
- As tarifas de demanda de potência, nos horários de ponta e fora de ponta, em R\$/kW;
- As tarifas de demanda de ultrapassagem, nos horários de ponta e fora de ponta, em R\$/kW;
- A quantidade de indivíduos (população inicial) e quantidade de gerações;
- A taxa de mutação; e
- O valor de *alfa*, variável para auxiliar no crossover.

A taxa de mutação citada acima se deve ao fato de que na teoria da evolução, alguns indivíduos tem seus códigos genéticos modificados por um processo denominado de mutação, modificando assim, tanto o seu genótipo quanto o seu fenótipo. Na teoria dos AG's, uma taxa de mutação é inserida propositalmente, a fim de aumentar a variedade das características dos indivíduos de uma população, bem como também de seus descendentes.

A variável alfa, também citada anteriormente, é utilizada durante o cruzamento dos indivíduos. Foi utilizado pela primeira vez por (ESHELMAN e SHAFFER, 1993) na teoria do *blend-crossover*, em que o cruzamento dos indivíduos são realizados através de números reais e não binários. Resumidamente, a teoria diz que dados dois cromossomos  $p_1$  e  $p_2$ , é produzido um cromossomo  $c$  da seguinte forma:  $c = p_1 + \beta(p_2 - p_1)$ . Onde  $\beta \sim U(-\alpha, 1+\alpha)$ , onde  $U$  representa uma distribuição uniforme. Tipicamente  $\alpha = 0,5$  ou  $0,25$ .

#### 4.2 Quantidade de Gerações

Embora os AG's se apresentem como um método de otimização bastante eficiente, ele não assegura que o mínimo global de uma função seja encontrado, e sim, valores muito próximos a este mínimo global. Então, a quantidade de gerações é o critério de parada para este trabalho. Esta quantidade é escolhida de forma empírica, a fim de que as gerações passem de forma adequada pelo processo de evolução.

#### 4.3 Inicialização da População

Por meio do histórico das curvas de carga, é possível ter conhecimento dos valores máximos e mínimos das demandas medidas. Então, a população é inicializada com valores aleatórios entre estes dois limites.

Para o caso em estudo da UFRN, por exemplo, dentre as demandas medidas no ano de 2018, a menor e a maior demanda medida na ponta foram de 3.292,80 kW e 6.232,80 kW, ocorridos nos meses de Janeiro e Novembro, respectivamente. Para as demandas medidas no horário fora de ponta, o menor e o maior valor registrados foram, 5.006,40 kW e 7.795,20 kW, ocorridos nos meses de Janeiro e Março, respectivamente.

Portanto, a população inicial é gerada aleatoriamente, respeitando os limites mínimo e máximo das demandas medidas avaliadas para aquele período. Vale lembrar que, para este trabalho, o indivíduo, que é o valor de demanda a ser contratada, é composto de duas partes, mostradas na Figura 3: a primeira delas é a demanda na ponta, e a outra parte é a demanda fora de ponta, ambas dadas em kW. O indivíduo constitui, assim, um vetor de números reais, de dimensão  $1 \times 2$ , e a população constituirá uma matriz cuja dimensão é  $n \times 2$ , onde  $n$  é a quantidade de indivíduos daquela população.

#### 4.4 Função Objetivo

A função objetivo provê o mecanismo para avaliar cada indivíduo da população, atribuindo-lhe o conceito (*fitness*) para cada solução. Como o problema consiste em minimizar, quanto menor o valor da função objetivo, os indivíduos terão mais chances de sobreviver e gerar filhos mais aptos. O modelo de otimização aplicado ao problema da demanda contratada deste trabalho é descrito como:

Minimizar:

$$z = \sum_{i=1}^{12} [T_{DP} \cdot D_{FP} + U_p \cdot T_{UP} + T_{DF} \cdot D_{ff} + U_f \cdot T_{UF}] \quad (1)$$

Sujeito a

$$D_{fp} = \text{máx}(D_{mp}, D_{cp}) \quad (2)$$

$$D_{ff} = \text{máx}(D_{mf}, D_{cf}) \quad (3)$$

$$U_p = D_{mp} - D_{cp} \quad (4)$$

$$U_f = D_{mf} - D_{cf} \quad (5)$$

$$D_{cp} \geq 2.500 \text{ kW (Limite inferior de Demanda na ponta)} \quad (6)$$

$$D_{cf} \geq 2.500 \text{ kW (Limite inferior de Demanda fora de ponta)} \quad (7)$$

Em que

$T_{DP}$  = Tarifa de Demanda na Ponta, em R\$/kW;

$T_{DF}$  = Tarifa de Demanda Fora de ponta em R\$/kW;

$T_{UP}$  = Tarifa de Ultrapassagem na Ponta, em R\$/kW;

$T_{UF}$  = Tarifa de Ultrapassagem Fora de ponta, em R\$/kW;

$D_{fp}$  = Demanda Faturada na Ponta, em kW;

$D_{ff}$  = Demanda Faturada Fora de ponta, em kW;

$U_p$  = Demanda Ultrapassada na Ponta em kW;

$U_f$  = Demanda Ultrapassada Fora de ponta, em kW;

$D_{cp}$  = Demanda contratada na ponta, em kW; e

$D_{cf}$  = Demanda contratada fora de ponta, e kW

O valor de limite inferior da demanda contratada informado nas restrições se deve ao fato de que, para os consumidores atendidos em tensão de fornecimento de 69 kV, a demanda a ser contratada não pode ser inferior a 2.500 kW (ANEEL, REN 414/2010, art.12, inciso IV).

As variáveis  $D_{fp}$  e  $D_{ff}$  equivalem ao maior valor entre a demanda medida e a demanda contratada, na ponta e fora de ponta, respectivamente. As demandas medidas são obtidas dos

históricos disponíveis nas faturas de energia elétrica e são introduzidas no programa como dados de entrada. Os valores de demandas geradas aleatoriamente representam os diversos indivíduos de uma população que serão avaliados um a um no algoritmo.

Os valores de tarifas utilizados na simulação para o ano de 2018 são de: R\$ 19,39 e R\$ 11,06 para as demandas medidas na ponta e fora de ponta respectivamente. Estes valores são a média anual das tarifas utilizadas nos 12 meses do ano de 2018. Para os meses em que houve ultrapassagem da demanda contratada, as tarifas de ultrapassagem cobradas tem o dobro destes valores apresentados, conforme previsto pela Resolução 414/2010 da ANEEL. Lembrando que estes são os valores cobrados pela concessionária COSERN para os seus clientes enquadrados na modalidade tarifária horária azul em sua área de concessão.

A restrição da função objetivo é o limite inferior de demanda contratada que é de 2.500 kW para os consumidores atendidos em tensão de fornecimento de 69 kV ou superior e que estão obrigatoriamente enquadrados na modalidade tarifária horária azul.

#### 4.5 Seleção dos Pais

Como o melhor indivíduo da população inicial não corresponde à solução ótima do problema, uma seleção será necessária para que os melhores pais tenham maiores chances de serem escolhidos, segundo seus desempenhos, para executarem o cruzamento. O critério escolhido para selecionar os pais foi baseado no valor médio dos custos anuais de uma população. Se o custo anual devido àquele indivíduo for menor do que a média dos custos anuais daquela população, então este indivíduo está dentro do grupo dos mais aptos.

#### 4.6 Cruzamento (crossover)

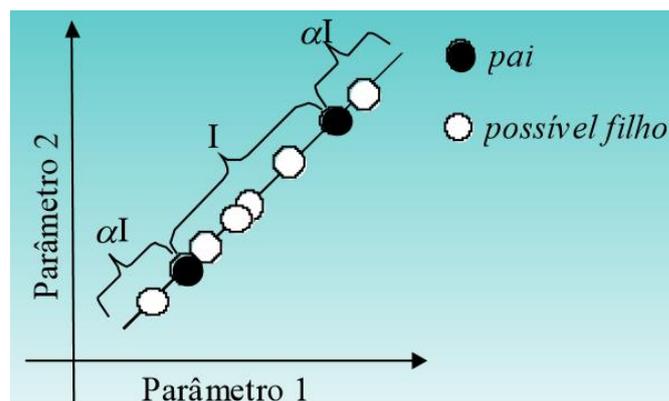
A etapa do *crossover*, ou cruzamento, se refere à geração de novos indivíduos. O *crossover* em um ponto está relacionado ao cruzamento cujos indivíduos são representados por uma cadeia de números binários. Para este trabalho, como os indivíduos são representações de números reais, o cruzamento utilizado foi através do *blend-crossover*.

Como já mencionado na seção 4.1, o *blend-crossover* foi introduzido pela primeira vez por (ESHELMAN e SHAFFER, 1993) e diz que dados dois pais  $p_1$  e  $p_2$ , um filho é gerado aleatoriamente de acordo com a fórmula:

$$c = p_1 + \alpha(p_2 - p_1) \quad (8)$$

Onde  $\alpha$  é escolhido geralmente como 0,5 ou 0,25. O provável filho gerado por este tipo de cruzamento se encontrará em um intervalo que é ilustrado na Figura 4.

Figura 4 – Localização do possível filho pelo blend-crossover



FONTE: Lacerda, 2008

#### 4.7 Mutação

A mutação é utilizada a fim de aumentar a diversidade da população. De maneira que o algoritmo faça a busca de forma mais eficiente, então alguns indivíduos podem sofrer mutações. À medida que as gerações vão se passando, os indivíduos vão ficando mais aptos e parecidos uns com os outros. Assim, aplicando a mutação, através de uma taxa de mutação pré-definida, o algoritmo permite que alguns indivíduos sofram alterações aleatoriamente, a fim de que a busca possa continuar a varrer algumas soluções ainda não alcançadas.

#### 4.8 Nova População

A cada casal de pais selecionados, são gerados dois filhos. Sendo que, dentre os dois filhos gerados, apenas um deles sobreviverá e passará para a próxima geração, que é o filho com melhor desempenho.

De modo que cada geração terá a mesma quantidade de indivíduos da sua geração ascendente, ou seja, as populações sempre serão representadas por matrizes de dimensão  $n \times 2$ . Este foi o critério escolhido para a evolução das gerações.

Sendo assim, será necessário avaliar o desempenho de cada par de filhos gerados, a fim de que o melhor dentre eles seja escolhido para passar à próxima geração.

## 5. SIMULAÇÕES E RESULTADOS

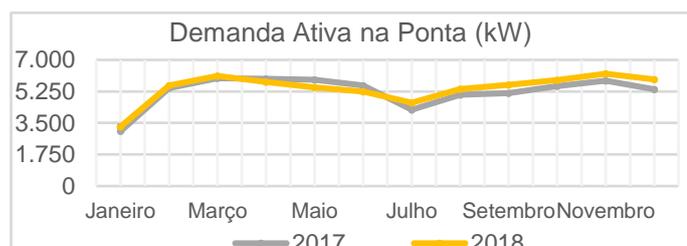
A fim de se obter dados anuais mais concretos, foram simulados valores com os dados de demanda nos anos de 2017 e 2018. Estes valores de demanda na ponta e fora de ponta estão apresentadas na Tabela 1, bem como também nos gráficos das Figuras 5 e 6.

Tabela 1 – Valores de demanda dos anos 2017 e 2018

Meses	Demanda na ponta em 2017 (kW)	Demanda fora de ponta em 2017 (kW)	Demanda na ponta em 2018 (kW)	Demanda fora de ponta em 2018 (kW)
Janeiro	3.040,80	4.754,40	3.292,80	5.006,40
Fevereiro	5.443,20	7.072,80	5.577,60	7.207,20
Março	5.980,80	7.526,40	6.115,20	7.795,20
Abril	5.947,20	7.593,60	5.779,20	7.291,20
Mai	5.896,80	7.224,00	5.476,80	6.921,60
Junho	5.577,60	6.854,40	5.241,60	6.434,40
Julho	4.233,60	5.174,40	4.620,00	5.779,20
Agosto	5.073,60	6.115,20	5.392,80	6.602,40
Setembro	5.157,60	6.148,80	5.611,20	6.854,40
Outubro	5.544,00	6.736,80	5.880,00	7.190,00
Novembro	5.846,40	7.039,20	6.232,80	7.526,40
Dezembro	5.376,00	6.686,40	5.913,60	7.476,00

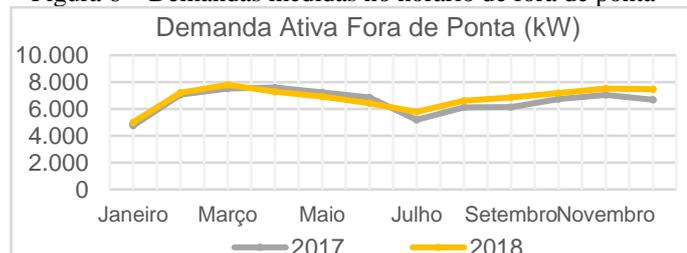
FONTE: Faturas mensais de energia elétrica

Figura 5 – Demandas medidas no horário de ponta



FONTE: Gerado no Excel a partir das faturas mensais de energia elétrica

Figura 6 – Demandas medidas no horário de fora de ponta



FONTE: Gerado no Excel a partir das faturas mensais de energia elétrica

### 5.1 Custos Reais

Os custos que a UFRN obteve devido a essas demandas medidas nos anos de 2017 e 2018 são apresentados na Tabela 2. Uma observação importante a ser mencionada neste ponto é a demanda contratada da UFRN que é de 6.634,00 kW, tanto na ponta como fora de ponta, este valor de demanda foi

contratado desde a entrada em operação da nova subestação e até a presente data ainda não passou por nenhuma revisão.

Tabela 2 – Custos devido à parcela de demanda nos anos de 2017 e 2018

Meses	Custo da Demanda em 2017 (R\$)	Custo da Demanda em 2018 (R\$)
Janeiro	188.619,72	183.946,58
Fevereiro	194.837,19	197.244,52
Março	201.264,37	212.154,12
Abril	162.924,15	205.644,75
Mai	196.979,58	204.710,99
Junho	195.909,27	201.522,89
Julho	188.619,72	205.818,13
Agosto	188.619,71	207.939,28
Setembro	191.903,57	208.839,81
Outubro	190.044,20	221.230,96
Novembro	195.003,43	230.244,89
Dezembro	184.641,85	225.145,51
<b>TOTAL (R\$)</b>	<b>2.279.366,76</b>	<b>2.504.442,43</b>

FONTE: Faturas mensais de energia elétrica

Assim, segundo dados das próprias faturas de energia elétrica do ano de 2018, a UFRN teve um custo de aproximadamente dois milhões e meio de reais apenas com a parcela da demanda contratada, isto representa aproximadamente 20% da conta de energia elétrica do campus central.

Para testar o algoritmo proposto neste trabalho, foram feitas três simulações. A Tabela 3 mostra o resumo das três simulações. Percebe-se que à medida que se aumenta o número de indivíduos e a quantidade de gerações, os valores dos custos anuais e a demanda contratada sugerida convergem a valores muito próximos uns dos outros. Os parâmetros para cada simulação foram: simulação 1 (40 indivíduos e 10 gerações), simulação 2 (80 indivíduos e 20 gerações) e simulação 3 (120 indivíduos e 30 gerações).

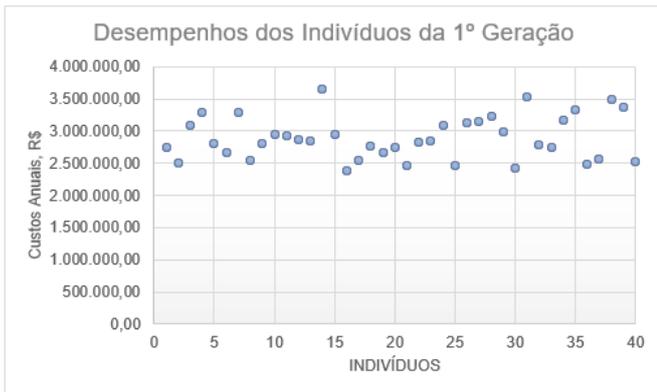
Com intuito de visualizar o processo de evolução, baseado na simulação 1, dados de 2018, o gráfico das Figuras 7 e 8 mostram como os indivíduos evoluíram, apresentando seus desempenhos (custos anuais) na primeira e na décima geração respectivamente.

Tabela 3 – Resumo das simulações

		2017	2018
SIMULAÇÃO 1	Custo anual (R\$)	2.099.323,00	2.354.399,20
	Demanda sugerida a ser contratada na ponta	5.709 kW	5.936 kW
	Demanda sugerida a ser contratada fora de ponta	6.900 kW	7.178 kW
SIMULAÇÃO 2	Custo anual (R\$)	2.096.643,50	2.347.675,20
	Demanda sugerida a ser contratada na ponta	5.702 kW	5.647 kW
	Demanda sugerida a ser contratada fora de ponta	6.881 kW	7.170 kW
SIMULAÇÃO 3	Custo anual (R\$)	2.095.054,10	2.345.530,80
	Demanda sugerida a ser contratada na ponta	5.696 kW	5.632 kW
	Demanda sugerida a ser contratada fora de ponta	6.880 kW	7.168 kW

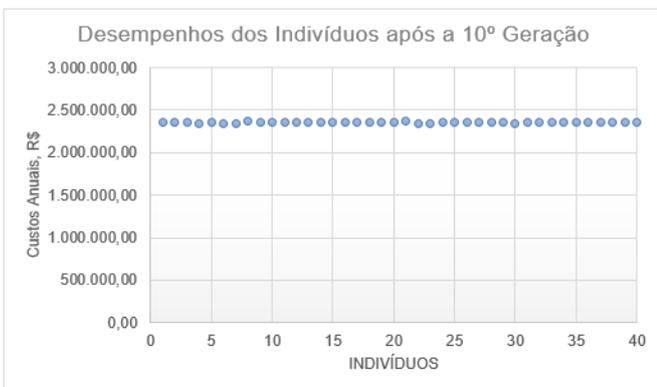
FONTE: Elaboração própria

Figura 7 – Desempenhos dos indivíduos da primeira geração



FONTE: Gráfico gerado no Excel

Figura 8 – Desempenhos dos indivíduos após a décima geração

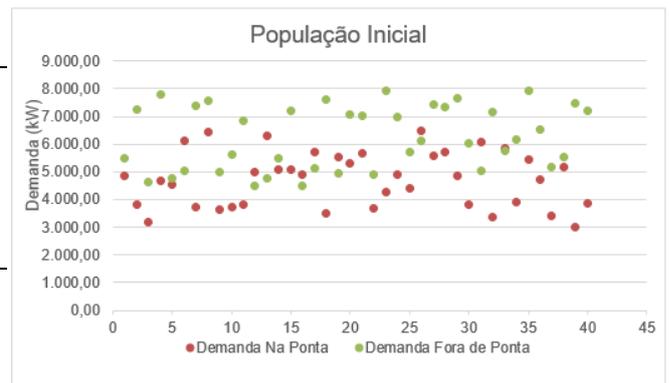


FONTE: Gráfico gerado no Excel

Percebe-se que, na décima geração, que é a última desta simulação, os indivíduos (demanda contratada) apresentaram desempenhos (custos) bem próximos uns aos outros e também valores abaixo do menor custo do indivíduo da primeira geração.

Para uma melhor visualização da população foi plotado os gráficos das Figuras 9 e 10 que representam os indivíduos, resultantes da primeira simulação, com seus materiais genéticos (demandas na ponta e fora de ponta), da população inicial e da última geração respectivamente.

Figura 9 – Indivíduos da primeira geração, gerados aleatoriamente



FONTE: Gráfico gerado no Excel

Figura 10 – Indivíduos da última geração, convergindo para o valor ótimo



FONTE: Gráfico gerado no Excel

Foi possível notar nas simulações que, com o passar das gerações, os indivíduos vão apresentando seus materiais genéticos cada vez mais próximos uns dos outros, que significa a convergência para um valor ótimo de demanda contratada. As simulações mostraram também que, para uma população de aproximadamente 100 indivíduos, e a partir da vigésima geração, os valores de custo anual e as demandas contratadas sugeridas convergem para valores bem próximos aos apresentados pela simulação 3. As Tabelas 4 e 5 apresentam os resumos da comparação entre a situação ocorrida nos anos de 2017 e 2018 e a situação sugerida.

Tabela 4 – Comparação entre a situação ocorrida e a mudança sugerida para 2017

Modalidade Tarifária Atual	Azul
Demanda Contratada na ponta atualmente	6.634 kW
Demanda Contratada fora de ponta atualmente	6.634 kW
Custo Total Anual	R\$ 2.279.366,76
Modalidade Tarifária Sugerida	Azul
Demanda Contratada na ponta sugerida	5.696 kW
Demanda Contratada fora de ponta sugerida	6.880 kW
Custo Total Anual	R\$ 2.095.054,10
<b>Economia Total Anual</b>	<b>R\$ 184.312,66 (8,08%)</b>
<b>Economia Mensal Média</b>	<b>R\$ 15.359,39</b>

FONTE: Elaboração própria

Tabela 5 – Comparação entre a situação ocorrida e a mudança sugerida para 2018

Modalidade Tarifária Atual	Azul
Demanda Contratada na ponta atualmente	6.634 kW
Demanda Contratada fora de ponta atualmente	6.634 kW
Custo Total Anual	R\$ 2.504.442,43
Modalidade Tarifária Sugerida	Azul
Demanda Contratada na ponta sugerida	5.632 kW
Demanda Contratada fora de ponta sugerida	7.168 kW
Custo Total Anual	R\$ 2.345.530,80
<b>Economia Total Anual</b>	<b>R\$ 158.911,63 (6,35%)</b>
<b>Economia Mensal Média</b>	<b>R\$ 13.242,64</b>

FONTE: Elaboração própria

## 6. CONCLUSÕES

Analisando os resultados do algoritmo genético, conclui-se que o valor ótimo da demanda a ser contratada é alcançado na simulação 3, onde a população é formada por 120 indivíduos e 30 gerações. Simulações posteriores comprovaram que os valores dos custos se repetem para uma população com quantidade maior de indivíduos e de gerações, ou seja, a solução alcançada foi satisfatória.

Sabe-se, entretanto, que a situação ideal da busca, se encontra nos valores mínimos das funções minimizadas pelo algoritmo de otimização. Mas que estas situações se encontram sob incertezas, pois nos anos futuros o cenário de demanda poderá ser alterado, e influenciado por alguns fatores, como por exemplo, aumento de carga, inauguração de um novo edifício nas instalações do campus, reforma de um setor, dentre outros. Se os tomadores de decisão soubessem informações de qual seria exatamente o cenário futuro de demanda, então a otimização estaria garantida todos os anos.

No momento em que este artigo foi submetido, este estudo continua em fase de se aprofundar no tema, levando em consideração fatores como sazonalidade e incertezas no futuro. Outras meta-heurísticas estão sendo pesquisadas, como a aplicação dos algoritmos GWO (*Grey Wolf Optimizer*) e TLPO (Teaching-learning based optimization). Técnicas de Machine Learning também estão sendo estudadas no sentido reduzir os custos na contratação de energia no Mercado Livre.

## AGRADECIMENTOS

Agradeço a DEUS, razão da minha existência, autor e consumidor da minha fé, pelo dom da vida que Ele me deu, pela oportunidade e força para realizar este trabalho.

Agradeço à minha esposa, Paula Vanuccy, maior incentivadora dos meus estudos. E também ao meu orientador, professor Max Chianca, pela cordialidade que tratou desse trabalho.

## REFERÊNCIAS

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA – ANEEL. Resolução Normativa 414/2010 – Condições Gerais de Fornecimento de Energia Elétrica. Brasília/DF, 2012. Disponível em [www.aneel.gov.br](http://www.aneel.gov.br). Acesso em 06/02/2020.

ALBUQUERQUE, F. O. Otimização Robusta aplicada à Contratação de Energia Elétrica considerando incerteza na Demanda Futura. Dissertação de Mestrado Profissional. Instituto Tecnológico de Aeronáutica – ITA. 46f. 74. São José dos Campos/SP. 2015.

CHEN, C. Y.; LIAO, C. J. A linear programming approach to the electricity contract capacity problem. Elsevier, Applied Mathematical Modeling. 35 (2011) 4077-4082. Taiwan.

LACERDA, E. G. M. de. Algoritmos Genéticos com Parâmetros Contínuos. Tópicos de Aula. DCA/UFRN. Natal/RN. 2008.

L.J. Eshelman, J.D. Schaffer, "Real-Coded Genetic Algorithms and Interval-Schemata", *Foundations of Genetic Algorithms 2*, pp. 187-202, 1993.

OZUR, F. S.; PEREIRA, T. H. e CORREA, J. D. S. Sistema de Gerenciamento do Consumo e da Qualidade de Energia Elétrica. E-xacta, Belo Horizonte, v.4, n.3, p.191-202. 2011. Editora UniBH. Disponível em [www.unibh.br/revistas/exacta/](http://www.unibh.br/revistas/exacta/). ISSN 1984-3151. Aprovado em: 20.12.2011.

PACHECO, M., A., C. e ROCHA, J., E., N. Aplicação de Algoritmos Genéticos na Otimização de Contratos de Demanda de Energia Elétrica. Nota Técnica Inteligência Computacional – ICA. PUC-Rio. Rio de Janeiro/RJ. 2001.