

Maximização da receita de uma rede de voos pelo método de algoritmos genéticos

[Maximizing revenue flight of a network by the method of genetic algorithms]

Marcelo Xavier Guterres*, Henry Gomes de Carvalho, Luiz Biondi Neto, Antonio José da Silva

Universidade do Estado do Rio de Janeiro (UERJ), Brazil

Submitted 29 Aug 2011; received in revised form 16 Dec 2011; accepted 26 Jan 2012

Resumo

A competitividade entre as companhias aéreas exige o uso de técnicas inovadoras para previsão de demandas e maximização de receitas. A previsão de demanda está associada a variáveis internas, tal como o preço, e externas, tal como as condições econômicas. A maximização da receita, por sua vez, está associada ao planejamento operacional, tal como a programação de voos. Neste cenário, há uma ampla possibilidade de aplicação de técnicas de otimização. Inspirado nos mecanismos de evolução dos seres vivos, o método de algoritmos genéticos destaca-se pela facilidade de implementação, pois é aplicável em situações onde não se conhece o modelo matemático. A técnica apresenta bons resultados quando comparada com métodos determinísticos. Utilizando a técnica de algoritmos genéticos, este artigo mostra como é feita a modelagem do método para solução do problema de otimização para maximização de receita de uma rede de voos de uma pequena companhia aérea. É feita também, uma comparação entre os resultados obtidos pelos métodos de algoritmos genéticos e Simplex.

Palavras-Chave: transporte aéreo; otimização; algoritmos genéticos; programação linear.

Abstract

Competitiveness among airlines requires using of innovative techniques to forecast of demands and maximization of revenue. The forecast of demand with associated to inner variables, such as price, and outer, such as economic conditions. The Maximization of revenue, is turn, with associated to the operational planning, such as flight schedules. In this scenario, there is a wide possibility of optimization techniques application. Inspired by the evolution mechanisms of living beings, the genetic algorithms method is distinguished by implementation ease; it is applicable in situations where you do not know the mathematical model. The technique present good results when compared to deterministic methods. Using the generic algorithms technique, this paper shows how is the modeling method for solving the optimization problem to maximize revenue a flight network from a small airline. It also made a comparison among the results obtained by the generic algorithm methods and Simplex.

Key words: air transport; genetic algorithms; optimization; linear programming.

* Corresponding Author. Email: m.guterres@gmail.com.

Recommended Citation

Guterres, M. X., Carvalho, H. G., Neto, L. B. and Silva Neto, A. J. (2012) Maximização da receita de uma rede de voos pelo método de algoritmos genéticos. Journal of Transport Literature, vol. 6, n. 3, pp. 136-151.

1. Introdução

No início dos anos 90 a indústria de transporte aéreo brasileira começou a sofrer profundas mudanças estruturais devido a alterações no seu marco regulatório impostas pela autoridade aeronáutica. Uma das principais consequências deste processo foi à eliminação das barreiras à entrada de novas companhias (Guterres, 2002). Esta nova situação propiciou uma perspectiva de competição entre as empresas existentes, forçando-as a um novo tipo de posicionamento no mercado. O mercado competitivo fez com as companhias aéreas mudassem de uma política puramente operacional para uma política de negócios. Isto inclui o uso de técnicas inovadoras com a finalidade de prever as demandas futuras e maximização das receitas das suas redes de voos.

De acordo Corrêa, Gianesi e Caon (2006), no que diz respeito a prever a demanda futura com alguma precisão é importante que as empresas saibam utilizar as ferramentas disponíveis. Isso pode envolver a formar e manter uma base de dados históricos das viagens, assim como dados que expliquem suas variações e comportamento, isto é, compreender como as variáveis internas (preço, promoções, etc.) e variáveis externas (condições econômicas, etc.) influenciam o comportamento da demanda. Por outro lado, a maximização das receitas está associada ao planejamento operacional, cujo objetivo é a geração da programação horária de voos, que é o conjunto aeronave, ligação, escalas, frequência e horários de operação.

Assim, as atuais características da indústria do transporte aéreo indicam uma ampla possibilidade de aplicação de técnicas de otimização na solução dos problemas de planejamento e gestão que as firmas enfrentam.

No caso das pequenas companhias aéreas, cujas redes de voos normalmente possuem baixa demanda a escolha de rotas eficientes, não só afeta o desenvolvimento das operações, mas como também as decisões táticas e estratégicas, tais como o tamanho ideal da frota, estimativa de custos, desgaste do equipamento, entre outras variáveis de decisão.

Deste modo, o planejamento e a gestão de redes de voos de baixa demanda origina um elevado número de variáveis complexas de decisão a serem otimizadas, que podem a princípio não serem tratadas com técnicas de otimização determinísticas, logo, meta-

heurísticas e técnicas estocásticas são sempre alternativas viáveis, porém, não garantem a solução ótima do problema, mas podem fornecer boas soluções para problemas complexos reais.

Poucos trabalhos foram encontrados na literatura que estudam o planejamento operacional-tático-estratégico de uma pequena companhia aérea. Neste sentido, o presente artigo tem como objetivo abordar aspectos conceituais e resolutivos do uso de técnicas de previsão de demanda e de métodos de otimização no planejamento de pequenas empresas aéreas. Para tanto, será feito uma breve revisão da literatura e por fim será proposto um modelo de maximização de receita para uma pequena rede de voos utilizando Algoritmos Genéticos (AG).

Este artigo está organizado da seguinte maneira: a seção 2 faz uma breve revisão dos modelos clássicos de previsão de demanda em transporte aéreo. A seção 3 discute aspectos conceituais das técnicas de otimização baseada em algoritmos genéticos. Na seção 4 estuda-se a aplicação do modelo de planejamento otimizado em uma pequena rede de voos com baixa densidade de tráfego. Os resultados mostram que a técnica de algoritmos genética apresenta bons resultados quando comparada com a resposta obtida via método Simplex. Finalmente, a seção 5 apresenta as considerações finais deste estudo.

2. Modelagem Matemática da Projeção de Demanda em uma Ligação

Previsões de demanda desempenham um importante papel na operacionalização de diversos aspectos do gerenciamento da produção de uma empresa aérea. A estimativa do tráfego futuro é essencial no diz respeito ao planejamento da frota e alocação das aeronaves. Esses modelos são conhecidos como modelos de tráfego direcional e são voltados para mercados específicos (ex.: passageiros transportados na ligação São Paulo – Rio de Janeiro).

A primeira abordagem lógica para se projetar demanda de passageiros em uma rota é a de estudar a série temporal de dados e analisar a tendência de evolução. Esse procedimento, no entanto, é aplicável somente às rotas existentes e não leva em conta como diversos fatores econômicos, sociais e operacionais afetam a evolução do tráfego. É possível que, em rotas bem exploradas em regiões desenvolvidas social e economicamente, o uso de tendências históricas, para projeções num pequeno horizonte de tempo, seja prático e eficaz. Para o

Brasil, no entanto, o exame das pequenas séries temporais disponíveis para o tráfego de origem-destino evidencia a inadequação desta técnica para quase a totalidade das ligações aéreas, pela própria dificuldade e risco de se estabelecer uma tendência.

Um modelo clássico para estimar o fluxo de passageiros entre duas cidades ou regiões é o conhecimento modelo gravitacional. Na sua forma original, apresentada no século XIX, o modelo incluía as seguintes variáveis para descrever o fluxo ferroviário de passageiros entre estações distintas, em que:

N: número de passageiros;

P1 e P2: população das duas cidades;

D: distância entre as duas cidades;

C: Constante a ser determinada;

O modelo matemático sendo expresso pela equação (1):

$$N = \frac{C(P_1.P_2)}{D^2} \quad (1)$$

Ainda que adequado para o objetivo ao qual se aplicou, o modelo original não é aplicável à previsão de tráfego aéreo, a médio e longo prazo. Motivo disto é que as variáveis independentes incluídas são exclusivamente magnitudes físicas e não refletem os fatores econômicos, técnicos ou sociais que influem na evolução do tráfego aéreo com o tempo. Modelos gravitacionais generalizados (ou modificados), do tipo:

$$N = \frac{C(P_1.P_2)^\alpha}{D^\beta} \quad (2)$$

Onde *C*, α e β são coeficientes ajustados pelo método dos mínimos quadrados, são, até nossos dias, utilizados.

No Brasil, a análise do comportamento de fluxos de passageiros em ligações aéreas incorporou esta metodologia – modelos do tipo gravitacional generalizado, envolvendo variáveis relevantes das áreas de influência do par de cidades que definem a ligação. Tal metodologia, frequentemente utilizada nos estudos da ICAO, possui uma boa relação causal

entre a variável dependente e as variáveis independentes, que refletem não só os fatores socioeconômicos como também os tecnológicos que possam explicar o desenvolvimento do tráfego aéreo e / ou ainda, os fatores característicos de oferta de transporte aéreo entre as duas localidades.

A demanda ou o tráfego entre um par qualquer de localidades toma a forma de um produto de variáveis socioeconômicas das áreas de influência das cidades servidas e de características tecnológicas e / ou de oferta de transporte aéreo entre as mesmas. A estrutura típica dos modelos gravitacionais generalizados utilizados no Brasil é a seguinte:

$$T_{ij} = \alpha_0 \cdot (M_i \cdot M_j)^{\beta_1} \cdot (C_{ij})^{\beta_2} \quad (3)$$

Onde:

T_{ij}: volume de tráfego aéreo de passageiros entre as áreas de influência das localidades *i* e *j*;

M_i e *M_j*: variáveis socioeconômicas das áreas de influência das localidades *i* e *j*;

C_{ij}: variável característica da oferta de transporte aéreo entre *i* e *j*;

α₀, *β₁* e *β₂*: parâmetros a estimar.

O modelo exposto pode ser transformado e então ajustado por regressão linear, da seguinte forma:

$$\ln(T_{ij}) = \alpha_0 + \beta_1 \ln(M_i \cdot M_j) + \beta_2 \ln(C_{ij}) \quad (4)$$

3. Algoritmos Genéticos

Algoritmos Genéticos são inspirados nos mecanismos de evolução dos seres vivos e possuem como base os trabalhos de Darwin sobre a origem das espécies (Darwin, 1981 apud Azevedo, 1999), bem como a genética natural, principalmente devido aos trabalhos de Mendel (Dunn, 1950).

Algoritmos Genéticos foram inicialmente propostos por John H. Holland em 1975 em seu trabalho intitulado “Adaptation in Natural and Artificial Systems” (Holland, 1975). O motivo de buscar na natureza a inspiração baseia-se no fato de que ela consegue resolver satisfatoriamente problemas altamente complexos, tal como a sobrevivência das espécies.

Algoritmos Genéticos trabalham com um conjunto de indivíduos denominados população, no qual, cada membro poderá ser a solução desejada. Cada indivíduo é codificado em uma cadeia de bits, denominada de cromossomo. A cadeia de cromossomos é representada por números binários. A função a ser otimizada é o ambiente.

Por analogia com o a natureza, espera-se que, através dos mecanismos de evolução das espécies e a genética natural, somente os mais aptos se reproduzam. O grau de aptidão de cada indivíduo é feito pela avaliação do mesmo através da função a ser otimizada.

Se o objetivo for obter o máximo da função, a aptidão é diretamente proporcional ao valor da função. Caso o objetivo seja obter o mínimo da função, a aptidão será inversamente proporcional ao valor da mesma (Tanomaru, 1995). Neste processo, cada nova geração será uma evolução da anterior. Assim, os mais aptos deverão possuir maior probabilidade de serem selecionados, de modo que a nova geração seja, em média, melhor do que a que lhe deu origem.

Existem dois operadores principais de recombinação genética para a geração de novos indivíduos, o crossover e a mutação. O crossover se dá pela troca de cromossomos entre dos dois indivíduos pais. Há várias formas possíveis de se fazer o cruzamento. O operador crossover, mais simples, é o chamado crossover de um ponto, onde, um local de cruzamento é escolhido com probabilidade uniforme sobre o comprimento do cromossomo e, então, os *strings* correspondentes são permutados. Há, ainda, muitas outras técnicas de crossover, como é o caso do crossover de dois pontos e de tipos uniformes. Entretanto, não existe consenso sobre qual técnica é a melhor.

A idéia básica do Algoritmo Genético clássico pode ser descrita de maneira sucinta, pelo Algoritmo:

- 1: $P \leftarrow$ População Inicial;
- 2: **enquanto** condição não satisfeita faça
- 3: $P_0 \leftarrow$ Seleção(P);
- 4: $P \leftarrow$ Cruzamentos(P_0);
- 5: $P \leftarrow$ Mutações(P);
- 6: **fim enquanto**
- 7: Solução \leftarrow Melhor indivíduo(P);

Para Orgo e Silveira (2007) alguns fatores que têm feito os Algoritmos Genéricos se tornarem uma técnica bem sucedida são: Simplicidade de operação, Facilidade de Implementação, Eficácia na busca da região onde, provavelmente, encontra-se o máximo ou mínimo global, serem aplicáveis em situações em que não se conhece o modelo matemático.

4. Estudo de Caso de uma Rede de Voos

Considerar-se-á uma empresa de transporte aéreo regional que atende a seguinte rede de voos: A-B, B-C e CD, que geram seis possíveis itinerários, ressaltados na tabela 01. O trecho A-B e C-D é feito com uma aeronave de 160 lugares divididos em duas classes (executiva e econômica), já o trecho B-C é percorrido com uma aeronave de 140 lugares, que também apresenta duas opções de classes para os usuários do serviço (figura 1).

Figura 1: Itinerários da Empresa



Considerando-se que as estimativas das demandas nas ligações foram obtidas com aplicação de um modelo de tráfego direcional, representado pela equação (4), e as aeronaves alocadas são frutos do *fleet planning*, processo de escolha das aeronaves adequadas para uma operação específica, e que a firma não pratica *overbooking*, estratégia que implica dispor para venda um número de assentos maior do que o existente, para compensar os efeitos dos

cancelamentos, formular-se-á um modelo *de fleet assignment*, que consiste em um modelo matemático para a maximização da receita da rede (Lopes, 1990).

Tabela 1: Dados de Tarifa e Demanda

Itinerários	Tarifa (\$)		Demanda	
	Classe Y	Classe C	Classe Y	Classe C
A – B	300,00	400,00	90	30
B – C	200,00	250,00	40	50
C – D	300,00	360,00	50	25
A – C	400,00	480,00	70	30
A – D	700,00	840,00	80	40
B – D	400,00	450,00	60	30

4.1 Modelagem do problema utilizando programação linear

O modelo de programação linear proposto apresenta a seguinte função objetivo:

$$\max L = \sum_{i=1}^m \sum_{j=i+1}^n T_{y_{ij}} \cdot X_{y_{ij}} + \sum_{i=1}^m \sum_{j=i+1}^n T_{c_{ij}} X_{c_{ij}} \quad (5)$$

Onde:

y: classe econômica

c: classe executiva

$T_{y_{ij}}$: valor da tarifa da classe *y* da origem *i* para o destino *j*;

$T_{c_{ij}}$: valor da tarifa da classe *c* da origem *i* para o destino *j*;

$X_{y_{ij}}$: número de assentos da classe *y* da origem *i* para o destino *j*;

$X_{c_{ij}}$: número de assentos da classe *c* da origem *i* para o destino *j*;

m: número de origens;

n: número de destinos = *m*+1;

L: lucro;

Sujeito as seguintes restrições:

- Capacidade das aeronaves: o número total de passageiros nos trechos não pode exceder a capacidade da aeronave no trecho;
- Demanda: os assentos que serão alocados em cada classe por itinerário não pode exceder a demanda estimada para a classe;

Para resolver este problema de programação linear foi utilizado o software LINDO (*Linear, Interactive, and Discrete Optimizer*), que utiliza o Método determinístico SIMPLEX. No anexo 01 pode ser visto a entrada de dados e a resposta obtida.

Conclui-se que a solução ótima está em distribuir primeiramente toda a demanda média de passageiros na classe executiva. Como podemos ver na tabela 2, apenas no itinerário A-C não foi alocado à demanda média da classe executiva, nos demais itinerários foi reservado o número de assentos equivalentes à demanda média da classe executiva, isto ocorre, devido ao fato que a classe executiva gera mais receita, pois possui uma tarifa maior.

Tabela 2: Dados de Tarifa, Demanda e Receita Ótima

Itinerários	Tarifa (\$) Classe Y	Tarifa (\$) Classe C	Assentos Classe Y	Assentos Classe C	Receita
A – B	300,00	400,00	75	30	34.500,00
B – C	200,00	250,00	5	50	13.500,00
C – D	300,00	360,00	50	25	24.000,00
A – C	400,00	480,00	0	0	0,00
A – D	700,00	840,00	15	40	44.100,00
B – D	400,00	450,00	0	30	13.500,00
Total					R\$ 129.600,00

No modelo proposto de programação linear para maximização da receita da rede de voos da empresa aérea regional, percebe-se que não existe uma restrição ativa quanto a um número determinado de assentos na classe executiva e econômica. Logo, no modelo usado, um aumento no número de assentos na classe executiva e econômica não implicaria nenhuma

alteração na resposta, pois o modelo tem como restrição ativa a demanda média de passageiros na classe executiva.

Caso o modelo tivesse como restrição ativa o número de assentos das classes, uma eventual mudança no interior da aeronave ocasionaria mudança na maximização da receita, pois um aumento na classe executiva ocasionaria um aumento na receita, e caso contrário uma diminuição na receita.

4.2 Modelagem do problema utilizando Algoritmos Genéticos

A seguir, resolveremos o modelo proposto na secção (4.1) com Algoritmos Genéticos, com a finalidade de comparar as repostas obtidas por ambos os métodos.

Para aplicação do AG utilizou-se o *Matlab* com seu *Genetic Algorithm and Direct Search Toolbox* (*Gatool*). Este *toolbox* é uma implementação completa de AG, com seleção, mutação e cruzamento.

A estrutura do cromossomo corresponde a cada uma das possíveis soluções para o problema proposto, já o número de Indivíduos da População define quantos cromossomos (vetores) o algoritmo genético vai utilizar para iniciar o processo de busca da solução ideal.

A equação (5), que é função a ser otimizada é reescrita na sintaxe apropriada para o *Matlab*, como:

$$\begin{aligned} \text{maximizar } f = -1 * (300x_1 + 400x_2 + 200x_3 + 250x_4 + 300x_5 + 360x_6 \\ + 400x_7 + 480x_8 + 700x_9 + 840x_{10} + 400x_{11} + 450x_{12}) \end{aligned} \quad (6)$$

Onde:

x_1 : Número de assentos da classe *y* (econômica) no itinerário **A-B**;

x_2 : Número de assentos da classe *c* (executiva) no itinerário **A-B**;

x_3 : Número de assentos da classe *y* (econômica) no itinerário **B-C**;

x_4 : Número de assentos da classe *c* (executiva) no itinerário **B-C**;

x_5 : Número de assentos da classe *y* (econômica) no itinerário **C-D**;

x_6 : Número de assentos da classe *c* (executiva) no itinerário **C-D**;

x_7 : Número de assentos da classe *y* (econômica) no itinerário **A-C**;

x_8 : Número de assentos da classe *c* (executiva) no itinerário **A-C**;

x_9 : Número de assentos da classe *y* (econômica) no itinerário **A-D**

x_{10} : Número de assentos da classe *c* (executiva) no itinerário **A-D**;

x_{11} : Número de assentos da classe *y* (econômica) no itinerário **B-D**;

x_{12} : Número de assentos da classe *c* (executiva) no itinerário **B-D**;

As restrições são dadas pela capacidade máxima da aeronave (numero de assentos) em cada trecho. Portanto, todos os voos que dependem do trecho *A-B* estão restritos a 160 assentos. Do mesmo modo, os voos que participam do trecho *B-C* possuem a lotação máxima de 140 assentos. Finalmente, os voos participantes do trecho *C-D* estão limitados a 140 lugares. Tais restrições permitem expressar as seguintes inequações:

$$x_1 + x_2 + x_7 + x_8 + x_9 + x_{10} \leq 160 \quad (7)$$

$$x_3 + x_4 + x_7 + x_8 + x_9 + x_{10} + x_{11} + x_{12} \leq 140 \quad (8)$$

$$x_3 + x_4 + x_7 + x_8 + x_9 + x_{10} + x_{11} + x_{12} \leq 140 \quad (9)$$

Concluída a modelagem matemática, foram realizadas 10 (dez) execuções do Algoritmo Genético com três diferentes tamanhos de população, a saber: 20, 60 e 120, totalizando 30 execuções. Os resultados obtidos com as simulações computacionais podem ser vistos nas Tabelas 03, 04 e 05 respectivamente.

Tabela 3: Solução por Algoritmos Genéticos com população inicial igual a 20

int	x1	x2	x3	x4	x5	x6	x7	x8	x9	x10	x11	x12	Receita
1	36,69	9,58	6,37	7,45	21,15	24,99	1,81	12,11	27,25	31,44	26,68	26,56	R\$ 107.964,13
2	6,31	30,00	0,25	1,37	17,07	2,07	0,71	29,31	28,56	40,00	11,11	28,64	R\$ 105.432,37
3	3,03	30,00	15,55	0,09	29,91	24,99	1,10	26,18	73,10	26,26	-2,01	-0,27	R\$ 119.316,74
4	17,13	15,57	0,59	1,23	36,20	8,61	27,73	17,90	77,95	3,04	-16,91	28,38	R\$ 108.566,81
5	33,19	30,00	23,31	0,13	34,85	25,00	1,36	29,73	29,91	29,89	0,70	24,95	R\$ 118.474,28
6	39,44	29,79	0,01	23,11	31,86	25,00	22,05	6,27	34,26	6,36	23,97	23,92	R\$ 109.593,04
7	42,38	10,75	0,29	30,65	42,31	10,39	1,02	0,78	35,51	39,13	34,43	-1,96	R\$ 112.561,17
8	25,33	29,86	0,00	29,32	18,39	7,93	6,83	11,78	55,50	30,70	7,15	-1,29	R\$ 110.546,30
9	33,13	8,49	27,04	0,07	27,66	14,51	25,35	21,19	11,71	39,80	8,44	6,36	R\$ 100.459,71
10	32,85	29,99	0,26	29,53	44,01	12,73	24,30	2,36	36,09	34,31	1,65	11,49	R\$ 117.842,56

Tabela 4: Solução por Algoritmos Genéticos com população inicial igual a 60

int	x1	x2	x3	x4	x5	x6	x7	x8	x9	x10	x11	x12	Receita
1	42,76	29,54	7,45	14,15	43,49	13,75	12,90	2,71	32,05	40,00	1,41	29,29	R\$ 123.911,38
2	40,11	21,03	1,54	1,60	32,69	24,77	5,35	28,98	24,79	39,68	30,13	7,92	R\$ 122.219,75
3	52,91	27,23	5,22	9,82	42,91	24,97	27,10	5,74	33,46	13,56	29,02	16,07	R\$ 119.371,62
4	29,08	27,15	4,19	7,90	34,93	24,92	1,20	26,72	35,98	39,75	22,83	1,41	R\$ 123.500,18
5	17,86	28,19	18,57	1,09	39,83	24,92	21,07	3,93	55,66	33,25	-7,63	13,94	R\$ 121.962,68
6	40,57	30,00	7,44	4,56	48,65	20,43	24,54	12,55	28,06	20,39	19,89	22,57	R\$ 119.469,85
7	30,82	29,07	4,36	10,08	47,17	23,00	6,74	28,93	24,42	40,00	1,64	23,75	R\$ 125.316,85
8	55,76	27,53	4,68	10,70	35,07	24,78	11,22	13,25	17,69	34,56	19,02	28,89	R\$ 123.654,67
9	50,36	19,64	9,41	4,68	36,18	24,28	19,02	7,34	42,27	21,38	6,45	29,38	R\$ 120.089,75
10	41,63	29,66	2,21	26,12	45,61	24,83	3,15	19,12	26,36	39,82	2,50	20,47	R\$ 126.505,51

Tabela 5: Solução por Algoritmos Genéticos com população inicial igual a 120

int	x1	x2	x3	x4	x5	x6	x7	x8	x9	x10	x11	x12	Receita
1	19,78	28,34	1,26	11,94	38,17	16,29	9,79	11,42	56,79	33,86	11,25	3,61	R\$ 121.546,13
2	19,82	27,39	6,79	24,33	50,00	21,35	5,05	15,10	52,63	40,00	-2,91	-1,08	R\$ 125.089,79
3	38,01	30,00	3,41	9,43	33,44	24,94	15,87	9,67	35,36	31,09	19,37	15,79	R\$ 122.161,97
4	32,83	29,65	7,59	5,45	49,31	24,57	32,60	8,24	28,07	28,60	17,58	11,86	R\$ 121.265,45
5	34,15	16,76	6,43	9,81	49,96	20,65	7,13	27,18	49,00	25,68	10,17	4,46	R\$ 120.949,00
6	22,15	29,89	6,86	10,38	32,48	23,18	10,20	8,23	64,87	24,62	-1,58	16,43	R\$ 121.528,83
7	60,28	11,38	29,72	12,41	49,83	24,92	8,68	3,97	35,87	39,83	12,22	-2,72	R\$ 123.200,45
8	57,51	29,49	24,32	6,33	36,08	24,66	8,58	1,57	24,14	38,66	8,29	28,10	R\$ 124.723,51
9	68,31	12,11	9,48	10,88	34,87	24,99	12,05	7,46	27,14	32,93	21,61	18,43	R\$ 121.408,31
10	23,46	29,84	22,12	3,98	50,00	11,84	13,80	1,93	61,10	29,86	1,29	5,86	R\$ 121.115,16

Na tabela 06, apresentamos a melhor solução obtida com o algoritmo genético.

Tabela 6: Solução ótima obtida pelo Algoritmo Genético

Solução por Algoritmos Genéticos com População Inicial 60													
int	x1	x2	x3	x4	x5	x6	x7	x8	x9	x10	x11	x12	Receita
10	41,63	29,66	2,21	26,12	45,61	24,83	3,15	19,12	26,36	39,82	2,50	20,47	R\$ 126.505,51

Analisando-se os resultados obtidos anteriormente, conclui-se que um aumento no tamanho da população de 20 para 60 gerou um conjunto de soluções melhores, porém a partir de 60 não se verificou a mesma situação, ou seja, não se observou alterações significativas dos desvios padrões dos valores de adaptação entre as populações de tamanho 60 e 120. E ainda o tempo computacional aumentou significativamente.

Tabela 7: Comparação entre as soluções do Método Simplex e o Algoritmo Genético

Método Determinístico	Simplex	Receita	R\$ 129.600,00
Método Estocástico	Algoritmo Genético	Receita	R\$ 126.505,51

Uma das desvantagens em se utilizar os AG para problemas que podem ser resolvidos pelo Método Simplex é que a solução obtida não é exata. No caso, a melhor solução obtida pelo algoritmo genético para a maximização da rede de voos possui um erro de 2,39%.

Por outro lado, uma das principais vantagens em se utilizar os AG é que eles começam o processo de gerações com uma população de soluções criadas aleatoriamente dentro do universo de busca. Na conclusão do processo têm-se não somente uma solução, mas uma população que pode representar o comportamento do problema, já que todos os indivíduos da população são soluções possíveis. Esta particularidade pode ser vantajosa em relação a ter apenas uma única solução ótima do problema (algumas soluções podem ser mais fáceis de implementar do que outras, por exemplo).

CONCLUSÕES

Este artigo buscou mostrar a importância do uso da modelagem matemática no planejamento das operações de uma empresa aérea, em particular de uma pequena companhia, visto que as atuais características da indústria do transporte aéreo indicam uma ampla possibilidade de aplicação de técnicas de otimização, em particular Algoritmos Genéticos, pois:

- A dimensão relativa (pequena) do transporte aéreo facilita a modelagem matemática, sua validação e controle.
- Sendo ela de capital intensiva em relação ao veículo, e dada a indivisibilidade da oferta, os investimentos em termos de frota de aeronaves são de grande monta. E mais: são investimentos de longa maturação (pela quase inexistência de “entrega imediata” das aeronaves). Assim, uma decisão errada pode comprometer irremediavelmente a situação econômico-financeira da empresa aérea;

- O usuário do modo aéreo prioriza o tempo. Desta forma, o planejamento e a coordenação da rede de processos e parcerias de modo a minimizar o tempo de produção são fundamentais;

Logo, a eficiência, a robustez e a habilidade de manipular variáveis de decisão complexas fazem dos AG uma ferramenta apropriada para aplicações de otimização na indústria do transporte aéreo.

Porém, ao se utilizar os algoritmos genéticos, o modelador deve ter claro que o tamanho da população determina o número de cromossomos na população, afetando diretamente o desempenho e a eficiência dos AG. Uma população pequena faz com que o desempenho diminua já uma grande população geralmente fornece uma cobertura representativa do domínio do problema, além de prevenir convergências prematuras para soluções locais ao invés de globais. No entanto, para se trabalhar com grandes populações, são necessários maiores recursos computacionais, ou que o algoritmo trabalhe por um período de tempo muito maior.

Por fim, as empresas aéreas, que buscam maximizar a utilização de suas aeronaves (consequentemente, o menor tempo de solo possível) e dos equipamentos ou serviços de rampa, além de oferecer o melhor nível de conforto para seus usuários, obrigatoriamente devem-se valer das técnicas de otimização para atingirem tal objetivo.

Referências

- Azevedo, F. M. V. (1999) Escola de Redes Neurais, Promoção: Conselho Nacional de Redes Neurais pp. c091-c121, Instituto Tecnológico de Aeronáutica, São José dos Campos, SP.
- Correia, H. L., Gianesi, L. e Caon, M. (2001) Planejamento Programação e Controle da Produção. 2º ed., São Paulo, Atlas.
- Darwin, C. (1859) On the Origin of Species, 1st edition, Harward University Press, Cambridge, MA, U.S.
- Guterres, M. X. (2002) Efeitos da Flexibilização do Transporte Aéreo Brasileiro sobre a Concentração da Indústria, Dissertação (Mestrado em Ciências) - Instituto Tecnológico de Aeronáutica, São José dos Campos, SP.
- Holland, J.H. (1975) Adaptation in natural and artificial systems, University of Michigan Press.

Lopes, D.R. (1990) Contribuição à modelagem do problema do planejamento da operação de pátios de aeronaves em aeroportos. Tese de Doutorado, EPUSP, São Paulo.

Orgo, I.Z e Silveira, S.R (2007) Algoritmo Genético para Gerenciamento de Rotas para Serviços de Tele Entrega. Anais do Seminário de Informática RS.

Tanomaru, J. (1995) Motivação, fundamentos e aplicações de algoritmos genéticos. Anais do II Congresso Brasileiro de Redes Neurais.

ANEXOS

1-Tela inicial de entrada dos dados



The screenshot shows the LINDO software window titled "LINDO - [D:\REDE2]". The menu bar includes "File", "Edit", "Solve", "Reports", "Window", and "Help". The toolbar contains various icons for file operations, solving, and help. The main text area displays the following linear programming model:

```

! Problema fleet assignment

max 300x1y+400x1c+200x2y+250x2c+300x3y+360x3c+400x4y+480x4c+700x5y+840x5c+400x6y+450x6c

st

! capacidade das aeronaves nos trechos

x1y+x1c+x4y+x4c+x5y+x5c<160
x2y+x2c+x4y+x4c+x5y+x5c+x6y+x6c<140
x3y+x3c+x5y+x5c+x6y+x6c<160

! Demanda

x1y<90
x1c<30
x2y<40
x2c<50
x3y<50
x3c<25
x4y<70
x4c<30
x5y<80
x5c<40
x6y<60
x6c<30

end

```

2- Solução do modelo

LP OPTIMUM FOUND AT STEP 12

OBJECTIVE FUNCTION VALUE

1) 129600.0

VARIABLE	VALUE	REDUCED COST
X1Y	75.000000	0.000000
X1C	30.000000	0.000000
X2Y	5.000000	0.000000
X2C	50.000000	0.000000
X3Y	50.000000	0.000000
X3C	25.000000	0.000000
X4Y	0.000000	100.000000
X4C	0.000000	20.000000
X5Y	15.000000	0.000000
X5C	40.000000	0.000000
X6Y	0.000000	0.000000
X6C	30.000000	0.000000

ROW	SLACK OR SURPLUS	DUAL PRICES
2)	0.000000	300.000000
3)	0.000000	200.000000
4)	0.000000	200.000000
5)	15.000000	0.000000
6)	0.000000	100.000000
7)	35.000000	0.000000
8)	0.000000	50.000000
9)	0.000000	100.000000
10)	0.000000	160.000000
11)	70.000000	0.000000
12)	30.000000	0.000000
13)	65.000000	0.000000
14)	0.000000	140.000000
15)	60.000000	0.000000
16)	0.000000	50.000000

NO. ITERATIONS= 12

RANGES IN WHICH THE BASIS IS UNCHANGED:

OBJ COEFFICIENT RANGES