

Dissertação de Mestrado

Alocação de Áreas de Espera em uma Rede de Filas com Serviços Gerais e Servidores Múltiplos

por

Gabriel Bahia Caldas

Fevereiro de 2012

Gabriel Bahia Caldas

Alocação de Áreas de Espera em uma Rede de Filas com Serviços Gerais e Servidores Múltiplos

Dissertação apresentada ao Programa de Pós-Graduação em Estatística do Instituto de Ciências Exatas da Universidade Federal de Minas Gerais como requisito parcial à obtenção do título de Mestre em Estatística.

Orientador: Frederico R. B. Cruz

Universidade Federal de Minas Gerais
Belo Horizonte, fevereiro de 2012



Universidade Federal de Minas Gerais
Instituto de Ciências Exatas
Departamento de Estatística
Programa de Pós-Graduação
Caixa Postal 702
31270-901 Belo Horizonte- MG – Brasil

Telefone (31) 3409-5923
Fax (31) 3409-5924
E-mail: pgest@ufmg.br
WEB: <http://www.est.ufmg.br/posgrad/>

FOLHA DE APROVAÇÃO

Alocação de Áreas de Espera em uma Rede de Filas com Serviços Gerais e Servidores Múltiplos

Gabriel Bahia Caldas

Dissertação defendida e aprovada pela banca examinadora constituída pelos Senhores:

PROF. FREDERICO RODRIGUES BORGES DA CRUZ
(Orientador/Departamento de Estatística/UFMG);

PROF. LUIZ HENRIQUE DUCZMAL
(Departamento de Estatística/UFMG);

PROF. ANDERSON RIBEIRO DUARTE
(Departamento de Matemática/UFOP).



Universidade Federal de Minas Gerais
Instituto de Ciências Exatas
Departamento de Estatística
Programa de Pós-Graduação
Caixa Postal 702
31270-901 Belo Horizonte- MG – Brasil

Telefone (31) 3409-5923
Fax (31) 3409-5924
E-mail: pgest@est.ufmg.br
WEB: <http://www.est.ufmg.br/posgrad/>

ATA DA DEFESA DE DISSERTAÇÃO DO ALUNO

Gabriel Bahia Caldas

Realizou-se, no dia 27 de Fevereiro de Dois mil e Doze, às 14:00 horas, na Sala 2076 do Instituto de Ciências Exatas da Universidade Federal de Minas Gerais, a 169ª defesa de dissertação de Mestrado em Estatística, intitulada “**Alocação de Áreas de Espera em uma Rede de Filas com Serviços Gerais e Servidores Múltiplos**”, apresentada por **Gabriel Bahia Caldas**, como requisito parcial para a obtenção do grau de Mestre em Estatística, à seguinte Comissão Examinadora: PROF. FREDERICO RODRIGUES BORGES DA CRUZ – ORIENTADOR (DEPARTAMENTO DE ESTATÍSTICA – UFMG); PROF. LUIZ HENRIQUE DUCZMAL – (DEPARTAMENTO DE ESTATÍSTICA – UFMG); PROF. ANDERSON RIBEIRO DUARTE – (DEPARTAMENTO DE MATEMÁTICA – UFOP).

A Comissão considerou a dissertação:

- Aprovada
 Aprovada condicionalmente, sujeita a alterações, conforme folha de modificações, anexa
 Reprovada, conforme folha de modificações, anexa

Finalizados os trabalhos, lavrei a presente ata que, lida e aprovada, vai assinada por mim e pelos membros da Comissão examinadora:

Belo Horizonte, 27 de Fevereiro de 2012.

Prof. Frederico Rodrigues Borges da Cruz
(Orientador/Departamento de Estatística/UFMG);

Prof. Luiz Henrique Duczmal
(Departamento de Estatística/UFMG);

Prof. Anderson Ribeiro Duarte
(Departamento de Matemática/UFOP).

Agradecimentos

Para alcançar os nossos objetivos, nós sempre contamos com o apoio de pessoas que estão ao nosso redor, e que direta ou indiretamente influenciam nos resultados das nossas conquistas, e por isso devo agradecer aqui especialmente a algumas pessoas.

Primeiramente eu devo agradecer aos meus pais, Cacilda Bahia e Alcides Queiroz, pois foram eles que sempre batalharam para que eu tivesse uma boa educação, e sempre me apoiaram nas minhas decisões. Agradeço a toda a minha família, que sempre me deu bastante carinho para matar a saudade nos momentos que fui à Salvador, minhas irmãs, Maisa, Jurema e Ana Helena, meus sobrinhos Lucas e Lúcia Helena, e meu sobrinho afilhado Luan Augusto.

Aos amigos Wecley Prates, Paulo Cerqueira, Rodolfo Lourenzutti, Vanessa Loureiro e Denise Duarte que foram tão importantes na hora de estudar as disciplinas, e que também, foram bastante importante nos momentos de descontração, em especial a professora Denise pelo apoio que foi dado desde o começo do curso. Não posso deixar de agradecer as minhas calouras do mestrado Talita Costa, Nívea Bispo e Izabella Alves também pelos momentos de descontração, que foram quase todos encontros gastronômicos e que me fizeram engordar um pouco em Belo Horizonte. Agradeço aos colegas do curso, que também tiveram importância pela convivência dentro e fora da universidade, e também aos meus amigos de fora do meio acadêmico, que sempre me deram bastante apoio.

Agradeço ao professor Frederico Cruz pela sua orientação, pela paciência, e pela confiança que foi depositada em mim, e por estar sempre disponível para sanar as minhas dúvidas. Também agradeço aos membros da banca, Luiz Duczmal (DE/UFMG) e Anderson Duarte (DM/UFOP) pelas correções e sugestões feitas à dissertação.

Também devo agradecer ao Departamento de Estatística da UFMG, pela estrutura oferecida, e ao CNPq, pelo incentivo dado ao projeto de pesquisa em forma de bolsa de mestrado.

A todos, o meu sincero obrigado!

Resumo

Nesta dissertação são apresentados resultados da análise empírica de um algoritmo proposto na literatura para alocação de áreas de espera em redes de filas finitas, abertas e acíclicas, com serviços gerais e servidores múltiplos. Dos resultados computacionais, concluímos que o tempo de processamento do algoritmo depende do número de servidores da rede, como era de se esperar, mas independe do quadrado do coeficiente de variação do tempo de serviço. Concluímos também que as alocações obtidas são robustas e que, em geral, o desempenho global previsto para a rede é acurado, conforme atestado por simulações. Finalmente, chegamos à conclusão que não é fácil encontrarem-se regras heurísticas do tipo ‘tal servidor múltiplo deve ocupar tal lugar na topologia’, antes de se aplicar um algoritmo de alocação de áreas de espera para determinar qual configuração é a melhor.

Palavras-chave: Planejamento de experimentos, redes de filas, filas finitas, análise de algoritmos, alocação de áreas de espera.

Abstract

In this dissertation, results are presented of an empirical analysis of an algorithm proposed in the literature for buffer allocation in finite open acyclic general-service multi-server queueing networks. From the computational results, we conclude that the processing time of the algorithm depends on the number of servers of the network (as expected) but it is independent of the squared coefficient of variation of service time. We also conclude that the allocations obtained are robust and that the approximations for the performance measures are accurate, as attested by simulation. Finally, we conclude that it is not easy to find heuristic rules, such as ‘this multiple server must take that place in the topology’, before applying a buffer allocation algorithm to determine which configuration is best.

Keywords: Design of experiments, queueing networks, finite queues, algorithm analysis, buffer allocation.

Sumário

Resumo	7
Abstract	8
Lista de Figuras	11
Lista de Tabelas	12
1 Introdução	1
1.1 Motivação	1
1.2 Contribuições	2
1.3 Organização	3
2 Origens e Trabalhos Anteriores	4
2.1 Notação	4
2.2 Formulação Matemática	6
2.3 Análise de Desempenho em Filas Únicas	7
2.4 Análise de Desempenho em Redes de Filas	9
2.5 Algoritmo de Otimização	13
2.6 Análise de Desempenho do Algoritmo de Otimização	16
3 Resultados Experimentais	18
3.1 Análise de Desempenho do Algoritmo	19
3.2 Análise das Alocações Obtidas	21
4 Discussão dos Resultados	24

5 Conclusões e Observações Finais	27
Referências Bibliográficas	29
A Dados Obtidos	33

Lista de Figuras

2.1	O método da expansão generalizado para duas filas adjacentes, i e j	9
2.2	Algoritmo de Powell	15
3.1	Redes de filas de teste na topologia série	19
3.2	Comparações múltiplas entre os níveis do número de servidores	20
3.3	Redes em topologia série com duas filas e três servidores . . .	21
A.1	Suposições iniciais do modelo proposto para análise de desem- penho (Fonte: MINITAB [®] 15)	35
A.2	Análise de resíduos do modelo ajustado (Fonte: MINITAB [®] 15)	35

Lista de Tabelas

3.1	Análise de variâncias para o tempo até convergência do algoritmo	20
3.2	Resultados para a rede de duas filas em série com serviços homogêneos	22
3.3	Resultados para a rede de duas filas em série com serviços heterogêneos	23
A.1	Resultados para a análise de desempenho do algoritmo	34

Capítulo 1

Introdução

1.1 Motivação

Modelos baseados em redes de filas são muito úteis para representar sistemas de manufatura discretos em geral (Bitran & Morábito, 1995, 1996). Em particular, podem também representar sistemas *job-shop* (Silva & Morábito, 2007a,b), mas existem várias outras aplicações possíveis (Morábito & Lima, 2000; Takeda et al., 2004; Doy et al., 2006; Iannoni & Morábito, 2006). Em *job-shops*, os nós dessas redes representam as estações de trabalho (*shops*), os produtos (*jobs*) representam os usuários com demanda por serviço nessas estações de trabalho e os arcos que conectam os nós da rede correspondem às rotas dos produtos.

Há vários tipos de redes de filas e uma descrição detalhada dos tipos mais populares pode ser encontrada na literatura (Silva & Morábito, 2007a). Nesse contexto, há o interesse por um tipo particular de filas, as filas finitas (isto é, com uma capacidade limitada) e com tempos de serviço gerais. Na conhecida notação de Kendall (1953) são as redes compostas por filas do tipo $M/G/c/K$, em que M corresponde a um processo de chegada markoviano (modelado pela distribuição exponencial), o G , a um tempo de serviço com distribuição geral, c é número de servidores em paralelo e, finalmente, K é o

número máximo de usuários no sistema incluindo aqueles em serviço (isto é, $K = c + x$, em que x é o tamanho da área de espera; do inglês *buffer*).

Uma das razões do interesse pelas filas $M/G/c/K$ é a sua flexibilidade em modelar áreas de espera finitas e taxas de serviço gerais, que são hipóteses bastante convenientes em aplicações reais (Smith & Cruz, 2005). Se por um lado as redes de filas $M/G/c/K$ têm tal flexibilidade, por outro a capacidade finita de áreas de espera abre a possibilidade de ocorrência do fenômeno de bloqueio, que é quando um usuário não pode seguir à fila seguinte, quando ela tem esgotada a sua capacidade máxima K . O bloqueio, agravado pela consideração de tempos de serviço gerais, acarreta características na forma não-produto. Formas não-produto dificultam a determinação de medidas de desempenho de cada fila $M/G/c/K$ individualmente (Smith, 2003) e tornam-se um problema ainda maior quando essas filas estão configuradas em redes (Smith et al., 2010).

1.2 Contribuições

A presente dissertação é uma complementação de um artigo recentemente publicado por Smith et al. (2010), em que, segundo os autores, foi proposto o primeiro algoritmo para alocação ótima de áreas de espera em redes de filas $M/G/c/K$ abertas e acíclicas. Desde que foi publicado este algoritmo, algumas questões permaneceram em aberto a respeito do seu desempenho. Neste trabalho pretendemos responder algumas delas.

Da análise dos resultados obtidos foi verificado que o número de servidores na rede influencia no tempo de processamento do algoritmo, mas não houve evidência estatística de que o coeficiente de variação também exercesse influência no tempo de processamento. Além disso, de acordo com as simulações realizadas, foi verificado que o desempenho global previsto para a

rede é acurado, também constatou-se que as alocações ótimas obtidas foram robustas. Concluímos que antes de se aplicar um algoritmo de alocação de áreas de espera para determinar qual configuração é a melhor, fica difícil estabelecer regras heurísticas do tipo ‘tal servidor múltiplo deve ocupar tal lugar na topologia’.

1.3 Organização

No próximo capítulo descrevemos as origens do problema e trabalhos anteriores relacionados a ele, bem como apresentamos os modelos matemáticos apropriados à análise das redes de filas e os algoritmos empregados para sua otimização. No Capítulo 3, apresentamos resultados experimentais obtidos para diferentes topologias de redes de filas, através de um experimento planejado. No Capítulo 4, discutimos os resultados obtidos. Por fim, no Capítulo 5, apresentamos conclusões e observações finais, além de levantarmos tópicos para possíveis trabalhos futuros na área.

Capítulo 2

Origens e Trabalhos Anteriores

A exemplo de vários artigos publicados nesta área (veja, por exemplo, [Yanasse et al., 2007](#); [Argoud et al., 2008](#)), o presente trabalho apresenta resultados de uma pesquisa de natureza aplicada com caráter experimental, de acordo com classificação amplamente aceita ([Miguel, 2010](#)). Entretanto, esta dissertação também possui características de levantamento do tipo *survey* exploratória ([Miguel & Ho, 2010](#)). De fato, as *surveys*, também conhecidas por pesquisa de avaliação, caracterizam-se pela utilização de técnicas de amostragem e análise e inferência estatística, bem como pela procura por relações entre as variáveis, de natureza causa-efeito. É exatamente o que será apresentado, em parte, nesta dissertação.

Em seguida, formalizamos matematicamente o problema, pois o algoritmo de resolução é derivado diretamente da sua formulação. Passemos inicialmente à definição da notação utilizada.

2.1 Notação

É necessário apresentar alguma notação, para o bom entendimento do trabalho:

- $G = (N, A)$, grafo direcionado, em que N é o conjunto de nós da rede

(filas do tipo $M/G/c/K$) e A é o conjunto de arcos da rede (ou pares de nós conectados);

- $\mathbf{p} = (\dots, p_{ij}, \dots)$, vetor das probabilidades de roteamento nos arcos $(i, j) \in A$;
- λ_i , taxa de chegada Poisson (markoviana) na fila $i \in N$;
- μ_i , taxa de serviço (com distribuição geral G) na fila $i \in N$;
- s_i^2 , quadrado do coeficiente de variação do tempo de serviço na fila $i \in N$, definido pela razão entre a variância e quadrado do valor esperado do tempo de serviço T_S , isto é, $\frac{V(T_S)}{E(T_S)^2}$;
- c_i , número de servidores em paralelo na fila $i \in N$;
- $\rho_i = \frac{\lambda_i}{c_i \mu_i}$, intensidade de tráfego na fila $i \in N$;
- K_i , capacidade total da fila $i \in N$, incluindo os itens em serviço;
- p_{K_i} , probabilidade de bloqueio, i.e., probabilidade de um item encontrar a fila i cheia;
- $x_i = K_i - c_i$, capacidade da área de espera da fila $i \in N$;
- $\Theta(\mathbf{x})$, taxa de atendimento (do inglês, *throughput*) global da rede, em função do vetor de alocação de áreas de espera, $\mathbf{x} = (x_1, x_2, \dots, x_n)$, em que n é a cardinalidade do conjunto N ;
- Θ^r , taxa de atendimento global mínima requerida.

2.2 Formulação Matemática

Um modelo de programação matemática inteira para o problema de alocação de áreas de espera em redes de filas $M/G/c/K$ (Smith et al., 2010), definido sobre o grafo direcionado $G = (N, A)$, é apresentado a seguir.

Modelo (M):

$$Z = \min \sum_{\forall i \in N} x_i, \quad (2.1)$$

sujeito a:

$$\Theta(\mathbf{x}) \geq \Theta^\tau, \quad (2.2)$$

$$x_i \in \{0, 1, \dots\}, \forall i \in N, \quad (2.3)$$

em que x_i (variável de decisão) é a capacidade da área de espera da i -ésima fila (isto é, é a capacidade da fila *excluindo-se* os itens em serviço), $\Theta(\mathbf{x})$ é a taxa de atendimento da rede de filas e Θ^τ é a taxa de atendimento global mínima requerida.

Note-se que, apesar de a função objetivo ser linear nas variáveis de decisão, x_i , este é um problema de otimização não-linear, por causa da restrição (2.2). Além disso, o modelo (2.1)-(2.3) envolve variáveis de decisão x_i inteiras, mas que serão relaxadas para simplificar sua solução. Finalmente, é importante ressaltar que a medida de desempenho aqui considerada é a taxa de atendimento global da rede, $\Theta(\mathbf{x})$, mas essa não é a única possibilidade. De fato, podemos encontrar na literatura o exame de problemas de alocação em redes de filas que consideram diferentes medidas de desempenho, tais como, por exemplo, o trabalho em processo (WIP, do inglês, *work-in-process*), o tempo total que um item leva para ser produzido (do inglês,

leadtime) (Bitran & Morábito, 1995; Silva & Morábito, 2007b), ou também várias medidas de desempenho conflitantes simultaneamente (análise de *tradeoff*) (Bitran & Morábito, 1996; Cruz et al., 2010).

2.3 Análise de Desempenho em Filas Únicas

Quando estamos tratando com uma fila finita única, a taxa de atendimento $\Theta(x)$ se relaciona diretamente com a taxa de chegada λ e a probabilidade de bloqueio p_K , que é a probabilidade que um item encontre o sistema cheio (isto é, o número de itens no sistema j iguala-se à sua capacidade total K):

$$\Theta(x) = \lambda(1 - p_K), \quad (2.4)$$

quando então o problema de determinação da medida de desempenho $\Theta(x)$ fica condicionado apenas à determinação da probabilidade de bloqueio p_K .

Para sistemas finitos markovianos puros com servidor único, isto é, filas $M/M/1/K$, com $\rho < 1$, a probabilidade de bloqueio pode ser encontrada em qualquer livro básico de teoria de filas (Gross et al., 2009):

$$p_K = \frac{(1 - \rho)\rho^K}{1 - \rho^{K+1}}. \quad (2.5)$$

Se relaxarmos a restrição de integralidade de K , podemos expressá-lo em função de ρ e p_K e chegar a uma expressão em forma fechada para o tamanho ótimo da capacidade total da fila:

$$K_M = \left\lceil \frac{\ln\left(\frac{p_K}{1 - \rho + p_K\rho}\right)}{\ln(\rho)} \right\rceil. \quad (2.6)$$

em que $\lceil x \rceil$ é o menor inteiro não inferior a x . Por conseguinte, está determinada a alocação ótima da área de espera para filas $M/M/1/K$:

$$x_M = K_M - 1. \quad (2.7)$$

Para filas $M/G/c/K$ a determinação da probabilidade de bloqueio torna-se um problema bem mais complicado e parece improvável a existência de um método exato geral. Entretanto, em artigos anteriores (Smith & Cruz, 2005; Smith et al., 2010) foi mostrado que o esquema de aproximação a dois momentos de Kimura (1996), baseado na expressão markoviana, Eq. (2.7), produz resultados satisfatórios:

$$x_{\epsilon, \text{Kimura}}(s^2) = x_M + \text{INT} \left[\frac{(s^2 - 1)\sqrt{\rho}}{2} x_M \right]. \quad (2.8)$$

Para filas $M/G/1/K$, por exemplo, com uma intensidade de tráfego ρ e um dado quadrado do coeficiente de variação do tempo de serviço (geral) s^2 , uma aproximação para a área de espera ótima é:

$$x_{\epsilon, \text{Kimura}} = \frac{\left[\ln \left(\frac{p_K}{1 - \rho + p_K \rho} \right) + \ln(\rho) \right] (2 + \sqrt{\rho} s^2 - \sqrt{\rho})}{2 \ln(\rho)}. \quad (2.9)$$

Por conseguinte, podemos explicitar p_K e determinar uma expressão fechada para a probabilidade de bloqueio para uma fila $M/G/1/K$, em função de K (para filas $M/G/1/K$, note que $K = 1 + x_{\epsilon, \text{Kimura}}$):

$$p_K = \frac{(1 - \rho) \rho \left(\frac{2 + \sqrt{\rho} s^2 - \sqrt{\rho} + 2(K - 1)}{2 + \sqrt{\rho} s^2 - \sqrt{\rho}} \right)}{1 - \rho \left(\frac{2 + \sqrt{\rho} s^2 - \sqrt{\rho} + (K - 1)}{2 + \sqrt{\rho} s^2 - \sqrt{\rho}} \right)}. \quad (2.10)$$

Podemos continuar esse processo e obter formas fechadas aproximadas para as probabilidades de bloqueio, p_K , para diferentes valores de c em sistemas $M/G/c/K$ (Smith, 2003), e, conseqüentemente, sua taxa de atendimento $\Theta(x)$, pela Eq. 2.4.

2.4 Análise de Desempenho em Redes de Filas

O problema de análise de desempenho em filas finitas torna-se muito mais complexo quando elas estão configuradas em redes. O método da expansão generalizado (GEM, do inglês, *generalized expansion method*) é uma técnica robusta e bastante eficaz de aproximação de medidas de desempenho de redes de filas finitas (Kerbache & Smith, 1987). O objetivo do GEM é modelar o atraso causado quando há bloqueio para seguir na próxima fila finita da rede. O método é caracterizado por uma combinação de tentativas repetidas e decomposição nó a nó, para cada fila i , que for sucedida por uma fila finita j , conforme apresentado na Figura 2.1.

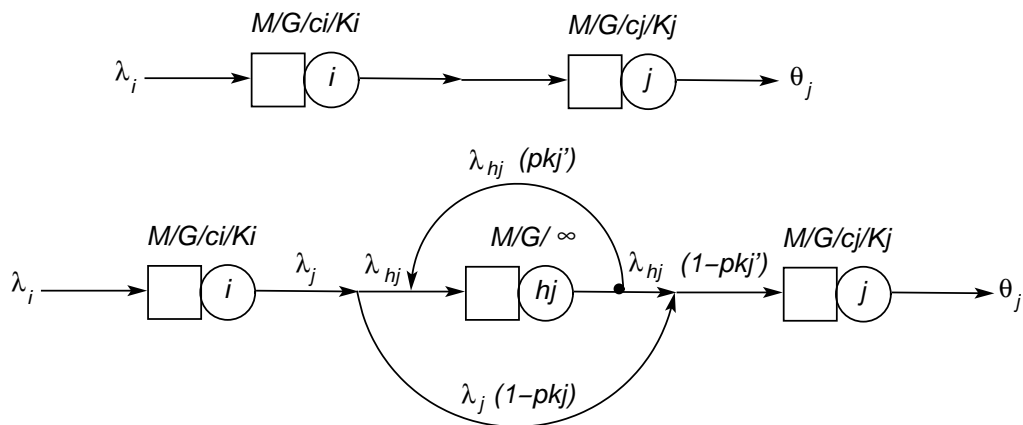


Figura 2.1: O método da expansão generalizado para duas filas adjacentes, i e j

O GEM possui três estágios, descritos a seguir, após a definição de uma

notação adicional:

- h_j , nó artificial, adicionado pelo GEM, antecedendo cada fila finita encontrada na rede;
- $\tilde{\lambda}_j$, taxa de chegada efetiva à fila j (descontados os itens que são bloqueados);
- $\tilde{\mu}_i$, taxa de serviço efetiva na fila i (devido ao bloqueio que sofreu da fila subsequente j);
- p'_{K_j} , probabilidade de bloqueio no laço de retro-alimentação no GEM.

Estágio I - Reconfiguração da Rede

Usando o princípio das duas fases da fila finita j (saturada ou insaturada), uma fila artificial de espera h_j , infinita, com um número infinito de servidores, do tipo $M/G/\infty$, é adicionada para cada fila finita na rede. A finalidade da fila de espera é registrar os itens bloqueados (ver Figura 2.1). Esta fila modela o atraso adicional, causados àqueles clientes que tentam entrar na fila j e a encontram cheia, o que ocorre com probabilidade p_{K_j} . Os itens são bem sucedidos na tentativa de entrar na fila j , com uma probabilidade $(1 - p_{K_j})$. Com essa fila artificial também são incluídos novos arcos na rede, com probabilidades de roteamento p'_{K_j} , caso o item continue bloqueado para um segundo período de atraso, e $(1 - p'_{K_j})$, caso possa prosseguir para a fila finita j . Este processo continua até que se encontre um espaço na fila finita j . Um arco de retroalimentação é utilizado para modelar esses repetidos atrasos. A fila artificial de espera é modelada como uma fila do tipo $M/G/\infty$ porque é usada simplesmente para dar ao item bloqueado um tempo extra de atraso, sem enfrentar filas.

Estágio II - Estimação de Parâmetros

Nesse estágio, estimamos aproximadamente os parâmetros p_{K_j} , p'_{K_j} e h_j , via resultados conhecidos para filas $M/G/c/K$, conforme descrito a seguir. Por simplicidade, omitiremos o subíndice j , referente à j -ésima fila finita.

p_K : as probabilidades de bloqueio podem ser obtidas pela utilização de resultados analíticos aproximados (nesta dissertação, será via aproximação a dois momentos de Kimura), como, por exemplo, para filas $M/G/1/K$, repetida a seguir por clareza,

$$p_K = \frac{(1 - \rho)\rho \left(\frac{2 + \sqrt{\rho}s^2 - \sqrt{\rho} + 2(K - 1)}{2 + \sqrt{\rho}s^2 - \sqrt{\rho}} \right)}{1 - \rho \left(\frac{2 + \sqrt{\rho}s^2 - \sqrt{\rho} + (K - 1)}{2 + \sqrt{\rho}s^2 - \sqrt{\rho}} \right)},$$

e, de forma similar, expressões para filas $M/G/c/K$, para valores $c = 2, 3, \dots, 10, \dots$, podem ser incluídas aqui, de forma a termos um conjunto completo de probabilidades de bloqueio;

p'_K : não há uma forma fechada para essa probabilidade (probabilidade de um segundo bloqueio) e utilizaremos a seguinte aproximação, obtida por técnicas de difusão ([Labetoulle & Pujolle, 1980](#)),

$$p'_K = \left\{ \frac{\mu_j + \mu_h}{\mu_h} - \frac{\lambda [(r_2^K - r_1^K) - (r_2^{K-1} - r_1^{K-1})]}{\mu_h [(r_2^{K+1} - r_1^{K+1}) - (r_2^K - r_1^K)]} \right\}^{-1}, \quad (2.11)$$

em que r_1 e r_2 são raízes do polinômio

$$\lambda - (\lambda + \mu_h + \mu_j)x + \mu_h x^2 = 0, \quad (2.12)$$

em que $\lambda = \lambda_j - \lambda_h(1 - p'_K)$, e λ_j e λ_h são taxas de chegadas efetivas à fila finita j e à fila artificial h , respectivamente;

μ_h : a distribuição do tempo de atraso causado por bloqueio na fila j é assumida ser a mesma da fila j e, por meio da teoria da renovação, é possível mostrar que o tempo de serviço na fila de espera possui média

$$\mu_h = \frac{2\mu_j}{1 + \sigma_j^2 \mu_j^2}, \quad (2.13)$$

em que σ_j^2 é a variância do tempo de serviço (Kleinrock, 1975).

Estágio III - Eliminação da Retroalimentação

Devido ao laço de retroalimentação em torno da fila de espera, haverá uma grande dependência no processo de chegada à fila j . A eliminação dessas dependências requer a reconfiguração da fila de espera, o que pode ser feito por um ajuste no seu tempo de serviço, dado por:

$$\mu'_h = (1 - p'_K)\mu_h. \quad (2.14)$$

As probabilidades de a fila j estar em uma das duas fases (saturada ou não-saturada) são p_K e $(1 - p_K)$, respectivamente. Assim, o tempo de serviço médio na fila i , que precede uma fila finita j , é μ_i^{-1} , quando na fase não-saturada, e $\mu_i^{-1} + p_K(\mu'_h)^{-1}$, na fase saturada. Portanto, o tempo médio de serviço corrigido $\tilde{\mu}_i$, para a fila i , é dado por:

$$\tilde{\mu}_i^{-1} = \mu_i^{-1} + p_K(\mu'_h)^{-1}. \quad (2.15)$$

Detalhes não serão fornecidos aqui, mas equações similares podem ser estabelecidas para cada um das filas finitas, tanto em configurações em série,

como também em fusão, em divisão e mista, o que completa a descrição do GEM.

2.5 Algoritmo de Otimização

Segundo [Smith et al. \(2010\)](#), uma forma eficiente de resolver o problema de alocação de áreas de espera aqui examinado, definido pelas Equações (2.1)-(2.3), é pela incorporação da restrição (2.2) na função objetivo, através de uma função de penalidade, tal como a relaxação lagrangeana ([Lemaréchal, 2007](#)). Assim, definindo-se uma variável dual α e relaxando-se a restrição (2.2), o seguinte problema relaxado é obtido:

Modelo (MR):

$$Z_\alpha = \min \left[\sum_{\forall i \in N} x_i + \underbrace{\alpha (\Theta^\tau - \Theta(\mathbf{x}))}_{\leq 0} \right], \quad (2.16)$$

sujeito a:

$$x_i \in \{0, 1, \dots\}, \forall i \in N, \quad (2.17)$$

$$\alpha \geq 0. \quad (2.18)$$

Se o problema (2.1)-(2.3) tiver solução viável e o vetor \mathbf{x} for *viável*, o termo $\alpha(\Theta^\tau - \Theta(\mathbf{x}))$ será sempre não-positivo (a taxa limiar Θ^τ deverá ser atendida e nunca poderá ficar abaixo de $\Theta(\mathbf{x})$, a taxa de saída) e será uma penalidade da função objetivo. Segue assim que $Z_\alpha \leq Z$, isto é, Z_α será um limite inferior para Z , que é o valor ótimo da função objetivo do problema (2.1)-(2.3).

O melhor limite inferior será dado pela solução ótima do seguinte problema, conhecido como dual lagrangeano:

Modelo (DL):

$$\max Z_\alpha, \quad (2.19)$$

sujeito a:

$$x_i \in \{0, 1, \dots\}, \forall i \in N, \quad (2.20)$$

$$\alpha \geq 0. \quad (2.21)$$

A taxa de saída limiar Θ^τ pode ser definida como sendo exatamente igual à taxa de entrada λ . Assim, um algoritmo aproximado como o GEM pode determinar a taxa de saída correspondente, $\Theta(\mathbf{x})$, que é a medida de desempenho de interesse. É possível perceber que nestas condições (se a taxa de saída limiar Θ^τ for exatamente igual à taxa de chegada externa λ), o melhor (maior) limite inferior dado pelo modelo (DL) será alcançado quando $\alpha \rightarrow \infty$, o que não é prático, pois exigiria que $(\Theta^\tau - \Theta(\mathbf{x})) = 0$ e que por conseguinte $x_i \rightarrow \infty$.

Por outro lado, se uma ‘pequena’ diferença, digamos $(\Theta^\tau - \Theta(\mathbf{x})) = \epsilon$, for aceitável, será necessário que seja verificado que $\alpha(\Theta^\tau - \Theta(\mathbf{x})) \leq 1$, pois caso contrário teria sido melhor gastar uma unidade a mais de área de espera em alguma fila, para aumentar $\Theta(\mathbf{x})$ (lembramos que $\Theta(\mathbf{x})$ é uma função não-decrescente de \mathbf{x}). Dessa forma, é possível definir um α_ϵ correspondente, como se segue:

$$\alpha_\epsilon \leq \frac{1}{(\Theta^\tau - \Theta(\mathbf{x}))}, \quad (2.22)$$

o qual, assumindo-se, por exemplo, $(\Theta^\tau - \Theta(\mathbf{x})) \leq 10^{-3}$, resultará em $\alpha_\epsilon = 10^3$ (será o valor aqui adotado).

A relaxação lagrangeana do problema primal, Z_α , acrescida de uma relaxação adicional na integridade das restrições para x_i , torna-se um problema clássico de otimização irrestrita. Conforme mostrado na literatura (Smith & Cruz, 2005; Smith et al., 2010), as variáveis x_i podem ser aproximadas razoavelmente por arredondamento de soluções provenientes de um algoritmo de otimização não-linear. Assim, a fim de resolver aproximadamente o problema (2.1)-(2.3), o GEM será acoplado a um clássico algoritmo de busca, o algoritmo de Powell.

```

algoritmo
  leia  $G(N, A)$ ,  $\mathbf{p}$ ,  $\boldsymbol{\lambda}$ ,  $\boldsymbol{\mu}$  e  $\mathbf{x}^{(0)}$ 
  escolha direções de busca linearmente independentes  $\mathbf{d}^{(1)}, \dots, \mathbf{d}^{(n)}$ 
   $\mathbf{x}^{(\text{opt})} \leftarrow \mathbf{x}^{(0)}$ 
  repita
     $\mathbf{x}^{(1)} \leftarrow \mathbf{x}^{(\text{opt})}$ 
    para  $i = 1$  até  $n$  faça
      /* executar busca unidimensional */
      /* calcular  $f(\bullet)$  com ajuda do GEM */
       $\mathbf{x}^{(i+1)} \leftarrow \arg \min_{\gamma \in \mathcal{R}} f(\mathbf{x}^{(i)} + \gamma \mathbf{d}^{(i)})$ 
    fim para
     $\mathbf{x}^{(n+2)} \leftarrow 2\mathbf{x}^{(n+1)} - \mathbf{x}^{(1)}$ 
    se  $f(\mathbf{x}^{(n+2)}) \geq f(\mathbf{x}^{(1)})$  então
       $\mathbf{x}^{(\text{opt})} \leftarrow \mathbf{x}^{(n+1)}$ 
    senão
       $\mathbf{x}^{(\text{opt})} \leftarrow \arg \min_{\gamma \in \mathcal{R}} f(\mathbf{x}^{(n+1)} + \gamma(\mathbf{x}^{(n+1)} - \mathbf{x}^{(1)}))$ 
      escolher novas direções de busca l.i.  $\mathbf{d}^{(1)}, \dots, \mathbf{d}^{(n)}$ 
    fim se
  até  $\|\mathbf{x}^{(\text{opt})} - \mathbf{x}^{(1)}\| < \epsilon$ 
  imprima  $\mathbf{x}^{(\text{opt})}$ 
fim algoritmo

```

Figura 2.2: Algoritmo de Powell

O método de Powell, apresentando esquematicamente na Figura 2.2, encontra o mínimo de uma função não-linear $f(\mathbf{x})$ por meio de sucessivas buscas unidimensionais, a partir de um ponto inicial $\mathbf{x}^{(0)}$, via um conjunto de direções conjugadas, que são geradas dentro do próprio procedimento. Ele

é baseado na ideia de que um mínimo de uma função não-linear $f(\mathbf{x})$ pode ser encontrado ao longo de n (dimensão do problema) direções conjugadas em um estágio da busca, com um passo adequado em cada direção. Maiores detalhes sobre o algoritmo de Powell podem ser encontrados facilmente na literatura ([Bazaraa et al., 2006](#)).

2.6 Análise de Desempenho do Algoritmo de Otimização

É de interesse prático verificar como o algoritmo de otimização se comporta, em termos de tempo de processamento até a convergência, em função de vários parâmetros da rede de filas finitas. Técnicas de planejamento de experimentos serão utilizadas para essa avaliação de desempenho do algoritmo. Em especial estaremos interessados na influência que o número de servidores, c , exerce sobre o tempo até convergência. Também é importante investigar se existe relação entre o quadrado do coeficiente de variação do tempo de serviço, s^2 , e o tempo até convergência, pois foi verificado que, em princípio, o s^2 influencia na alocação ótima das áreas de espera ([Smith et al., 2010](#)).

O delineamento probabilístico proposto para essa situação é um modelo fatorial ([Montgomery, 2008](#)), configurado em dois fatores (A e B) e em um bloco, sendo fixos tanto os fatores quanto o bloco. Como estamos interessados em saber se redes mais complexas aumentam o tempo de convergência, o número total de servidores na rede ($C = \sum_{v_i \in N} c_i$) será considerado o fator A . O outro fator de interesse é o quadrado do coeficiente de variação do tempo de serviço (s^2), chamado de fator B . Uma possível interação entre os fatores A e B também será investigada. Note que a taxa de chegada (λ), outro parâmetro importante na área alocada, será considerada como bloco,

pois não desejamos neste momento, investigar sua influência no tempo de convergência do algoritmo. O modelo proposto é dado por

$$Y_{ijk} = \mu + \tau_i + \beta_j + (\tau\beta)_{ij} + \gamma_k + \epsilon_{ijk}, \quad (2.23)$$

em que:

- Y_{ijk} é a observação coletada sob o i -ésimo nível do fator A , o j -ésimo nível do fator B e no k -ésimo bloco;
- μ é a média global;
- τ_i é o efeito do i -ésimo nível do fator A , sujeito à restrição $\sum_i \tau_i = 0$;
- β_j é o efeito do j -ésimo nível do fator B , sujeito à restrição $\sum_j \beta_j = 0$;
- $(\tau\beta)_{ij}$ é o efeito da interação entre o i -ésimo nível do fator A e o j -ésimo nível do fator B , sujeito à restrição $\sum_i \sum_j (\tau\beta)_{ij} = 0$;
- γ_k é o efeito do k -ésimo bloco, sujeito à restrição $\sum_k \gamma_k = 0$;
- ϵ_{ijk} é a componente de erro aleatório associado à observação Y_{ijk} .

Temos ainda a suposição de que os componentes de erro ϵ_{ijk} são variáveis aleatórias independentes e identicamente distribuídas com distribuição normal de média zero e variância σ^2 , ou seja, $\epsilon_{ijk} \stackrel{iid}{\sim} \mathcal{N}(0, \sigma^2)$.

Capítulo 3

Resultados Experimentais

Todos os algoritmos descritos foram codificados em *FORTRAN*, pela conhecida eficiência e exatidão de suas subrotinas numéricas. Os experimentos foram divididos em duas partes:

- Inicialmente foi feita uma análise de desempenho do algoritmo de alocação de áreas de espera, em termos do tempo de processamento até a convergência;
- Em seguida, aplicamos o algoritmo para determinação das alocações ótimas em algumas configurações simples, mas que permitiram conclusões interessantes a respeito do padrão de alocação de áreas de espera.

Inicialmente fizemos uma análise de desempenho do algoritmo de alocação de áreas de espera, em termos de tempo de processamento até a convergência. Em seguida, aplicamos o algoritmo a algumas configurações simples, mas que permitiram conclusões interessantes a respeito do problema de alocação de áreas de espera.

3.1 Análise de Desempenho do Algoritmo

No que diz respeito aos níveis dos fatores e do bloco, o experimento foi realizado adotando-se três redes de filas, com $N \in \{2; 4; 8\}$, com dois servidores em cada fila, perfazendo o total de 4, 8 e 16 servidores, respectivamente, conforme visto na Figura 3.1. Nessas redes de filas adotamos taxas de chegada $\lambda \in \{1; 2; 3\}$, para uma taxa de atendimento única $\mu = 4$, para todos os servidores. Finalmente, para o quadrado do coeficiente de variação do tempo de serviço consideramos $s^2 \in \{0, 5; 1, 0; 2, 0\}$. A variável de interesse são os tempos (em segundos) até a convergência do algoritmo. A ordem em que os experimentos foram executados foi aleatorizada, o mesmo acontecendo com a taxa de chegada λ .

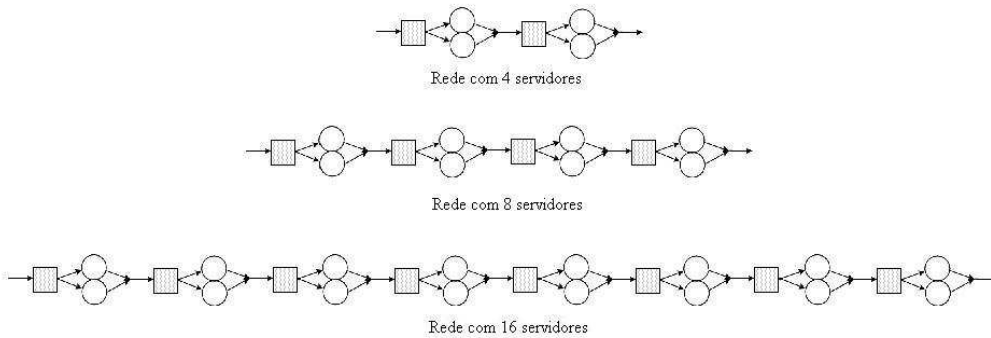


Figura 3.1: Redes de filas de teste na topologia série

Para essa análise foi utilizado um computador pessoal com o sistema operacional *Windows 7*TM. Os dados obtidos com a realização do experimento podem ser vistos no Anexo A. Usamos neste experimento a transformação logarítmica para os tempos até a convergência do algoritmo. Esta transformação foi necessária para satisfazer as suposições iniciais do modelo (2.23), tais como normalidade e homocedasticidade (i.e., variância constante dos erros). Essas e todas as demais suposições associadas ao modelo ajustado foram


respeitadas (Montgomery, 2008), conforme pode ser conferido no Anexo A.

Tabela 3.1: Análise de variâncias para o tempo até convergência do algoritmo

Fonte de variação	Graus de liberdade	Soma de quadrados	Quadrado médio	F	Valor- p
λ	2	2,9006	1,4503		
s^2	2	0,0279	0,0140	0,5	0,616
C	2	19,0475	9,5237	340,44	0,000
$s^2 \times C$	4	0,2878	0,0719	2,57	0,078
Erro	16	0,4476	0,0280		
Total	26	22,7114			

Fonte: MINITAB® 15

Na Tabela 3.1, apresentamos os resultados do ajuste do modelo (2.23). Na Figura 3.2 apresentamos os resultados da comparação múltipla (Hsu, 1996), entre as médias dos tempos até convergência, para os diferentes níveis do fator A (número total de servidores, C). Foi escolhido o fator A por ter-se mostrado significativo na análise de variâncias, para um nível de significância de 5% ($\alpha = 0,05$). Todos os resultados foram obtidos por meio do pacote estatístico MINITAB® 15.



Fonte: MINITAB® 15

Figura 3.2: Comparações múltiplas entre os níveis do número de servidores

3.2 Análise das Alocações Obtidas

Para uma análise das alocações ótimas fornecidas pelo algoritmo, utilizamos uma das topologias mais simples de rede de filas, que é uma configuração com duas filas em série e três servidores. As duas possibilidades para esta configuração são apresentadas na Figura 3.3. A questão que se coloca aqui é se uma configuração domina a outra. Isto é, queremos verificar se existe uma configuração mais eficiente que a outra, baseada apenas na ordem dos servidores.

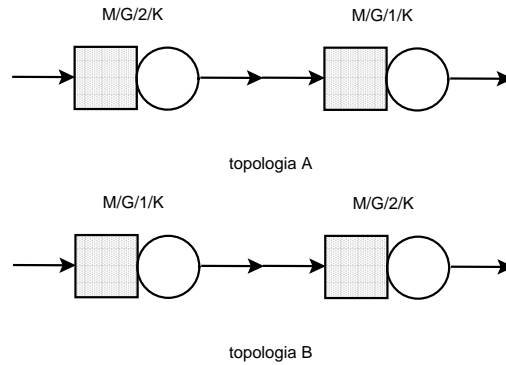


Figura 3.3: Redes em topologia série com duas filas e três servidores

O primeiro grupo de experimentos foi realizado considerando-se duas taxas de chegadas diferentes, $\lambda \in \{1; 2\}$, dois tempos médios de serviço, $\mu \in \{4; 8\}$, que foram iguais para todos os servidores (servidores homogêneos), e três valores para o quadrado do coeficiente de variação da taxa de serviço, $s^2 \in \{0, 5; 1, 0; 2, 0\}$. Os resultados podem ser vistos na Tabela 3.2.

Na Tabela 3.2, são apresentadas as alocações ótimas, \mathbf{x} , as taxas de atendimento alcançadas, $\Theta(\mathbf{x})$, e os valores da função objetivo penalizada, Z_α . Com o objetivo de avaliar a exatidão das aproximações analíticas, apresentamos também os resultados de simulações, em que a coluna δ dá a semi-amplitude dos intervalos de confiança de 95%. Essas simulações foram feitas

Tabela 3.2: Resultados para a rede de duas filas em série com serviços homogêneos

λ	μ	s^2	\mathbf{c}	\mathbf{x}	$\theta(\mathbf{x})$	Z_α	Simulação		
							$\theta(\mathbf{x})_s$	δ	$Z_{\alpha,s}$
1,0	(4,4)	0,5	(2,1)	(3, 4)	0,999	8,16	0,997	0,001	9,710
			(1,2)	(4, 3)	0,999	8,16	0,998	0,001	8,780
		1,0	(2,1)	(3, 4)	0,998	8,90	0,997	0,001	9,670
			(1,2)	(4, 3)	0,998	8,90	0,997	0,001	10,26
		2,0	(2,1)	(4, 5)	0,999	10,3	0,999	0,001	10,38
			(1,2)	(5, 5)	0,999	11,3	0,997	0,001	12,01
	(8,8)	0,5	(2,1)	(2, 3)	1,000	5,42	0,993	0,001	12,18
			(1,2)	(3, 2)	1,000	5,42	0,999	0,001	5,650
		1,0	(2,1)	(2, 3)	0,999	5,59	0,993	0,001	12,35
			(1,2)	(3, 2)	0,999	5,59	0,998	0,001	7,050
		2,0	(2,1)	(2, 3)	0,999	6,11	0,993	0,001	12,28
			(1,2)	(3, 2)	0,999	6,11	0,996	0,001	8,810
2,0	(4,4)	0,5	(2,1)	(7, 7)	1,997	16,8	2,001	0,015	13,40
			(1,2)	(7, 7)	1,997	16,8	1,997	0,001	16,80
		1,0	(2,1)	(8, 8)	1,997	19,2	2,000	0,002	17,60
			(1,2)	(8, 8)	1,997	19,2	1,999	0,002	18,90
		2,0	(2,1)	(9, 11)	1,996	23,7	2,000	0,001	20,20
			(1,2)	(11, 9)	1,996	23,7	1,997	0,001	23,50
	(8,8)	0,5	(2,1)	(4, 4)	1,999	9,03	2,001	0,002	7,500
			(1,2)	(4, 4)	1,999	9,03	1,998	0,001	10,40
		1,0	(2,1)	(4, 5)	1,999	9,95	2,000	0,002	8,900
			(1,2)	(5, 5)	1,999	11,0	2,000	0,002	8,800
		2,0	(2,1)	(4, 5)	1,997	11,7	1,999	0,002	10,50
			(1,2)	(5, 4)	1,997	11,7	1,994	0,001	14,90

no Arena[®], com 20 replicações, para determinação do δ , adotando-se um período de estabilização (do inglês, *burn-in*) de 20.000 unidades de tempo e um tempo total de simulação de 100.000 unidades de tempo. Para simular os tempos de serviço gerais com $s^2 \in \{0, 5; 2, 0\}$ utilizamos a distribuição gama, com parâmetros α e β adequados.

No segundo grupo de experimentos, com configuração bastante semelhante à do primeiro grupo, consideramos desta vez que os servidores eram heterogêneos, com taxas de serviço $\mu = 4$ e $\mu = 8$, alternadamente em cada servidor, sempre com a taxa menor para a fila com o maior número ($c = 2$) de servidores. Os resultados podem ser vistos na Tabela 3.3.

Tabela 3.3: Resultados para a rede de duas filas em série com serviços heterogêneos

λ	μ	s^2	\mathbf{c}	\mathbf{x}	$\theta(\mathbf{x})$	Z_α	Simulação		
							$\theta(\mathbf{x})_s$	δ	$Z_{\alpha,s}$
1,0	(4,8)	0,5	(2,1)	(3, 3)	0,999	6,95	0,997	0,001	8,670
			(1,2)	(3, 3)	0,999	6,95	0,999	0,001	6,720
	(4,8)	1,0	(2,1)	(3, 3)	0,999	7,39	0,997	0,001	8,870
			(1,2)	(3, 3)	0,999	7,39	0,998	0,001	8,130
	(4,8)	2,0	(2,1)	(4, 3)	0,999	8,15	0,999	0,001	8,320
			(1,2)	(3, 4)	0,999	8,15	0,996	0,001	10,930
2,0	(4,8)	0,5	(2,1)	(7, 4)	1,998	13,1	1,999	0,002	14,100
			(1,2)	(4, 7)	1,998	13,1	1,999	0,002	14,400
	(4,8)	1,0	(2,1)	(8, 5)	1,998	14,7	2,001	0,002	14,300
			(1,2)	(5, 9)	1,998	15,7	2,000	0,001	15,200
	(4,8)	2,0	(2,1)	(9, 5)	1,997	17,4	2,000	0,001	14,300
			(1,2)	(5, 9)	1,997	17,4	1,995	0,002	19,200

Capítulo 4

Discussão dos Resultados

Com relação à análise de desempenho do algoritmo, notamos pela coluna de valores- p da Tabela 3.1 que, adotando-se um nível de significância de 5% ($\alpha = 0,05$), o fator A (número total de servidores, C) foi significativo. O mesmo não aconteceu com o fator B (quadrado do coeficiente de variação do tempo de serviço, s^2). Percebemos também que não existiu interação entre os fatores A e B .

Nas comparações múltiplas da Figura 3.2, notamos que os intervalos de confiança construídos não possuem o valor zero. Isso indica que existe diferenças entre os valores médios para esses níveis do fator A . A rede com 16 servidores possui um tempo médio de convergência significativamente maior que as redes com 8 e 4 servidores. Além disso, os tempos médios de convergência para os níveis 4 e 8 também apresentam diferenças significativas entre si. O tempo médio para a rede com 8 servidores é maior que o para a rede com 4.

Sobre as alocações ótimas de áreas de espera (ver Tabelas 3.2 e 3.3), de um modo geral os valores encontrados foram bastante encorajadores. As alocações foram bastante estáveis, ou seja, com pequenas mudanças nos parâmetros da rede, têm-se mudanças também pequenas na alocação ótima.

Um ponto que merece destaque é a influência que exerceu o quadrado do coeficiente de variação do tempo de serviço, s^2 , na da área de espera alocada ótima, reforçando-se a importância de se desenvolver metodologias para tratar filas com tempos de serviço gerais. Uma metodologia que, por exemplo, fizesse uma aproximação markoviana para os tempos de processamento, teria a tendência a alocar uma área de espera menor que a necessária em sistemas hiper-exponenciais (i.e., com taxas de serviço com $s^2 > 1$). Similarmente, a aproximação markoviana tende a alocar áreas de sobra em sistemas hip-exponenciais (com $s^2 < 1$).

Quanto à qualidade das soluções analíticas aproximadas, os resultados mostraram-se mais modestos. Dos 24 experimentos realizados com redes homogêneas (Tabela 3.2), 15 deles tiveram seus valores analíticos confirmados pelos intervalos de confiança de 95% (com 6 valores analíticos fora dos intervalos de confiança). Dos 12 experimentos realizados com redes heterogêneas (Tabela 3.3), a metade dos resultados analíticos aproximados foi confirmada por simulação. Também, em alguns casos, as diferenças entre os valores das soluções analíticas e simuladas, Z_α e $Z_{\alpha,s}$, foram relativamente grandes (maiores que 50%). Isso é explicado em parte pelo valor alto utilizado para a variável dual α ($\alpha = 1000$). Esses resultados dão uma ideia da dificuldade que é a determinação de medidas de desempenho para filas finitas configuradas em redes.

Comparando-se a alocação das áreas de espera para as topologias A e B, Figura 3.3, é difícil dizer que uma topologia supera a outra, em termos de valor de função objetivo, apesar de existir uma pequena diferença nas respectivas soluções ótimas, Z_α . Assim, não podemos afirmar que existe o domínio de uma topologia sobre a outra. Fica difícil, portanto, estabelecer regras que prevejam qual topologia é a melhor, em função apenas do posicionamento

dos servidores.

O conjunto de experimentos com redes heterogêneas (i.e., diferentes taxas de serviço), Tabela 3.3, também leva a algumas conclusões importantes. Eles indicam que o desempenho pode ser independente do tipo de topologia, se for utilizada uma combinação adequada entre o número de servidores e a taxa de serviço. De fato, as taxas de saída foram similares, tanto para os casos em que a fila mais lenta estava no início da rede ($\mu = 4$), quanto para quando era a mais rápida ($\mu = 8$). Outro ponto que merece destaque é que, conforme esperado, áreas de espera maiores foram designadas para as filas com menor taxa de serviço. Em outras palavras, os servidores com menor capacidade de atendimento têm uma tendência a receber uma maior área de espera, para compensar.

Capítulo 5

Conclusões e Observações Finais

Apresentamos em detalhes um algoritmo recentemente proposto na literatura ([Smith et al., 2010](#)), para alocação de áreas de espera em redes de filas $M/G/c/K$ abertas e acíclicas. Por meio de um experimento planejado inédito, concluímos que o tempo de processamento do algoritmo depende do número de servidores dessas redes. Além disso, o quadrado do coeficiente de variação do tempo de serviço não interfere significativamente no tempo de execução do algoritmo, apesar de influenciar na alocação ótima, o que é um resultado surpreendente.

Experimentos em configurações que ainda não haviam sido testadas indicaram que também nesses casos a alocação obtida pelo algoritmo é robusta e faz sentido. Além disso, a aproximação para a medida de desempenho de interesse (a taxa de saída) também se confirmou satisfatória, pois em grande parte dos casos ficaram dentro dos intervalos de confiança de 95%, que foram estimados por simulação.

Outro resultado interessante obtido foi que topologias diferentes podem resultar em um desempenho similar, se as áreas de espera são as ótimas. Dessa forma, não pareceu ser fácil a obtenção de regras heurísticas, tais como

‘o servidor múltiplo ocupa o primeiro lugar na topologia’, antes de aplicar um procedimento de otimização para dizer qual topologia é melhor. Sabe-se que a topologia é direcionada geralmente pela aplicação, mas tal resultado pode trazer alguma flexibilidade para aqueles casos em que topologias alternativas estejam competindo.

Sobre as possíveis direções que esta pesquisa pode tomar, podemos citar a aplicação do algoritmo a problemas reais na área de manufatura e montagem, que podem apresentar redes de tamanhos da ordem de centenas de nós ([Spinellis et al., 2000](#)). Não foi feita uma análise da ordem de complexidade do algoritmo de alocação, pois queríamos apenas nos assegurar que os resultados fossem acurados. Entretanto, pelo que se viu aqui, os tempos de processamento não cresceram dramaticamente com o aumento do número de nós da rede. Assim, pode ser que problemas reais bem grandes sejam resolvíveis pelo algoritmo. De fato, problemas de alocação de servidores em redes de filas finitas sem áreas de espera foram resolvidos por método similar para mais de uma centena de nós ([Andriansyah et al., 2010](#)).

Para problemas muito grandes, quando o tempo de processamento ficar proibitivo, pode-se empregar como último recurso técnicas de agregação. Essas são técnicas comumente utilizadas para reduzir o tamanho de redes em problemas reais, quando são retidos apenas os nós mais importantes da rede.

Outra possibilidade é incluir estudos sobre redes com laços de realimentação, muito encontrados em sistemas de manufatura, com fluxos reversos e retrabalho. Os laços de realimentação causam grande dependência entre as chegadas e precisam de cuidadosa consideração. Estas são apenas algumas possíveis ideias para futuros trabalhos nesta área.

Referências Bibliográficas

- Andriansyah, R., van Woensel, T., Cruz, F. R. B. & Duczmal, L. (2010). Performance optimization of open zero-buffer multi-server queueing networks, *Computers & Operations Research* **37**(8): 1472–1487.
- Argoud, A. R. T. T., Gonçalves Filho, E. V. & Tiberti, A. J. (2008). Algoritmo genético de agrupamento para formação de módulos de arranjo físico, *Gestão & Produção* **15**(2): 393–405.
- Bazaraa, M. S., Sherali, H. D. & Shetty, C. M. (2006). *Nonlinear Programming: Theory and Algorithms*, 3^a ed., Wiley-Interscience, New York, NY.
- Bitran, G. R. & Morábito, R. (1995). Um exame dos modelos de redes de filas abertas aplicados a sistemas de manufatura discretos: Parte II, *Gestão & Produção* **2**(3): 297–321.
- Bitran, G. R. & Morábito, R. (1996). An overview of tradeoff curve analysis in the design of manufacturing systems, *Gestão & Produção* **3**(2): 108–134.
- Cruz, F. R. B., van Woensel, T. & Smith, J. M. (2010). Buffer and throughput trade-offs in $M/G/1/K$ queueing networks: A bi-criteria approach, *International Journal of Production Economics* **125**(2): 224–234.
- Doy, F. E., Bressan, G., Pereira, G. H. A. & Magalhães, M. N. (2006).

- Simulação do serviço de correio eletrônico através de um modelo de filas, *Pesquisa Operacional* **26**(2): 241–253.
- Gross, D., Shortle, J. F., Thompson, J. M. & Harris, C. M. (2009). *Fundamentals of Queueing Theory*, 4^a ed., Wiley-Interscience, New York, NY.
- Hsu, J. (1996). *Multiple Comparisons: Theory and Methods*, Chapman and Hall/CRC, Boca Raton, FL.
- Iannoni, A. P. & Morábito, R. (2006). Modelo de fila hipercubo com múltiplo despacho e backup parcial para análise de sistemas de atendimento médico emergenciais em rodovias, *Pesquisa Operacional* **26**(3): 493–519.
- Kendall, D. G. (1953). Stochastic processes occurring in the theory of queues and their analysis by the method of imbedded Markov chains, *Annals Mathematical Statistics* **24**: 338–354.
- Kerbache, L. & Smith, J. M. (1987). The generalized expansion method for open finite queueing networks, *European Journal of Operational Research* **32**: 448–461.
- Kimura, T. (1996). A transform-free approximation for the finite capacity $M/G/s$ queue, *Operations Research* **44**(6): 984–988.
- Kleinrock, L. (1975). *Queueing Systems*, Vol. I: Theory, John Wiley & Sons, New York, NY.
- Labetoulle, J. & Pujolle, G. (1980). Isolation method in a network of queues, *IEEE Transactions on Software Engineering* **SE-6**(4): 373–381.
- Lemaréchal, C. (2007). The omnipresence of Lagrange, *Annals of Operations Research* **153**(1): 9–27.

- Miguel, P. A. C. (2010). *Metodologia de Pesquisa em Engenharia de Produção e Gestão de Operações*, Elsevier, Rio De Janeiro, RJ.
- Miguel, P. A. C. & Ho, L. L. (2010). *Metodologia de Pesquisa em Engenharia de Produção e Gestão de Operações*, Elsevier, Rio De Janeiro, RJ, Cap. 5 - Levantamento Tipo *Survey*, pp. 73–128.
- Montgomery, D. C. (2008). *Design and Analysis of Experiments*, 7^a ed., John Wiley & Sons, New York, NY.
- Morábito, R. & Lima, F. C. R. (2000). Um modelo para analisar o problema de filas em caixas de supermercados: Um estudo de caso, *Pesquisa Operacional* **20**(1): 59–71.
- Silva, C. R. N. & Morábito, R. (2007a). Análise de problemas de partição de instalações em sistemas job-shops por meio de modelos de redes de filas, *Pesquisa Operacional* **27**(2): 333–356.
- Silva, C. R. N. & Morábito, R. (2007b). Aplicação de modelos de redes de filas abertas no planejamento do sistema job-shop de uma planta metal-mecânica, *Gestão & Produção* **14**(2): 393–410.
- Smith, J. M. (2003). $M/G/c/K$ blocking probability models and system performance, *Performance Evaluation* **52**(4): 237–267.
- Smith, J. M. & Cruz, F. R. B. (2005). The buffer allocation problem for general finite buffer queueing networks, *IIE Transactions* **37**(4): 343–365.
- Smith, J. M., Cruz, F. R. B. & van Woensel, T. (2010). Topological network design of general, finite, multi-server queueing networks, *European Journal of Operational Research* **201**(2): 427–441.

- Spinellis, D., Papadopoulos, C. T. & Smith, J. M. (2000). Large production line optimization using simulated annealing, *International Journal of Production Research* **38**(3): 509–541.
- Takeda, R. A., Widmer, J. A. & Morábito, R. (2004). Aplicação do modelo hipercubo de filas para avaliar a descentralização de ambulâncias em um sistema urbano de atendimento médico de urgência, *Pesquisa Operacional* **24**(1): 39–71.
- Yanasse, H. H., Becceneri, J. C. & Soma, N. Y. (2007). Um algoritmo exato com ordenamento parcial para solução de um problema de programação da produção: Experimentos computacionais, *Gestão & Produção* **14**(2): 353–361.

Apêndice A

Dados Obtidos

A Tabela [A.1](#) apresenta os dados referentes ao experimento realizado para a análise de desempenho do algoritmo. Além dos tempos até a convergência, coluna CPU(s), resultados também disponíveis são as alocações ótimas, \mathbf{x} , as taxas de saída, $\Theta(\mathbf{x})$, e os valores da função objetivo, Z_α .

Na Figura [A.1](#), são verificadas as suposições iniciais do modelo proposto [\(2.23\)](#). Nota-se que os dados transformados seguem a distribuição normal e não há violação de variabilidade constante entre os fatores e o bloco.

A Figura [A.2](#) apresenta a análise residual do modelo ajustado [\(2.23\)](#). Note-se que não há nenhuma violação quanto à normalidade, homocedasticidade e independência dos resíduos, indicando a validade do modelo [\(2.23\)](#), bem como dos resultados e conclusões obtidos a partir dele.

Tabela A.1: Resultados para a análise de desempenho do algoritmo

λ	μ	s^2	\mathbf{c}	\mathbf{x}	$\theta(\mathbf{x})$	Z_α	ucp(s)
1,0	(4,4)	0,5	(2,2)	(3,3)	0,998	7,66	0,109
	(4,4,4,4)		(2,2,2,2)	(3,3,3,3)	0,997	15,3	0,265
	(4,4,4,4,4,4,4,4)		(2,2,2,2,2,2,2,2)	(3,3,3,3,3,3,3,3)	0,993	30,6	1,014
	(4,4)	1,0	(2,2)	(3,3)	0,998	8,34	0,172
	(4,4,4,4)		(2,2,2,2)	(3,3,3,3)	0,995	16,6	0,296
	(4,4,4,4,4,4,4,4)		(2,2,2,2,2,2,2,2)	(3,3,3,3,3,3,3,3)	0,991	33,2	1,123
	(4,4)	2,0	(2,2)	(4,4)	0,999	9,21	0,109
	(4,4,4,4)		(2,2,2,2)	(4,4,4,4)	0,998	18,4	0,312
	(4,4,4,4,4,4,4,4)		(2,2,2,2,2,2,2,2)	(4,4,4,4,4,4,4,4)	0,995	36,8	0,858
2,0	(4,4)	0,5	(2,2)	(7,7)	1,997	16,9	0,140
	(4,4,4,4)		(2,2,2,2)	(7,7,7,7)	1,994	33,8	0,218
	(4,4,4,4,4,4,4,4)		(2,2,2,2,2,2,2,2)	(7,7,7,7,7,7,7,7)	1,989	67,4	0,811
	(4,4)	1,0	(2,2)	(8,8)	1,997	18,6	0,078
	(4,4,4,4)		(2,2,2,2)	(8,8,8,8)	1,995	37,2	0,203
	(4,4,4,4,4,4,4,4)		(2,2,2,2,2,2,2,2)	(8,8,8,8,8,8,8,8)	1,990	74,2	0,655
	(4,4)	2,0	(2,2)	(9,9)	1,996	21,9	0,078
	(4,4,4,4)		(2,2,2,2)	(9,9,9,9)	1,992	43,7	0,281
	(4,4,4,4,4,4,4,4)		(2,2,2,2,2,2,2,2)	(9,9,9,9,9,9,9,9)	1,985	87,2	0,577
3,0	(4,4)	0,5	(2,2)	(15,15)	2,993	36,7	0,047
	(4,4,4,4)		(2,2,2,2)	(15,15,15,15)	2,987	73,1	0,125
	(4,4,4,4,4,4,4,4)		(2,2,2,2,2,2,2,2)	(15,15,15,15,15,15,15,15)	2,975	145	0,437
	(4,4)	1,0	(2,2)	(17,17)	2,993	41,2	0,062
	(4,4,4,4)		(2,2,2,2)	(17,17,17,17)	2,986	82,1	0,140
	(4,4,4,4,4,4,4,4)		(2,2,2,2,2,2,2,2)	(17,17,17,17,17,17,17,17)	2,973	163	0,499
	(4,4)	2,0	(2,2)	(21,21)	2,992	50,0	0,047
	(4,4,4,4)		(2,2,2,2)	(20,20,20,20)	2,980	99,6	0,187
	(4,4,4,4,4,4,4,4)		(2,2,2,2,2,2,2,2)	(20,20,20,20,20,20,20,20)	2,963	197	0,390

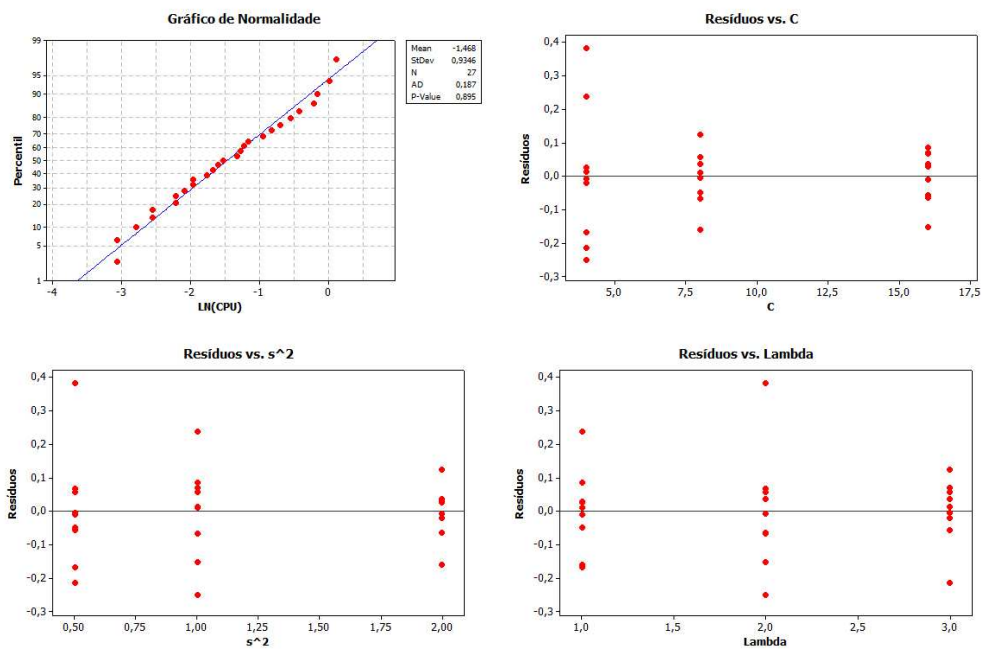


Figura A.1: Suposições iniciais do modelo proposto para análise de desempenho (Fonte: MINITAB® 15)

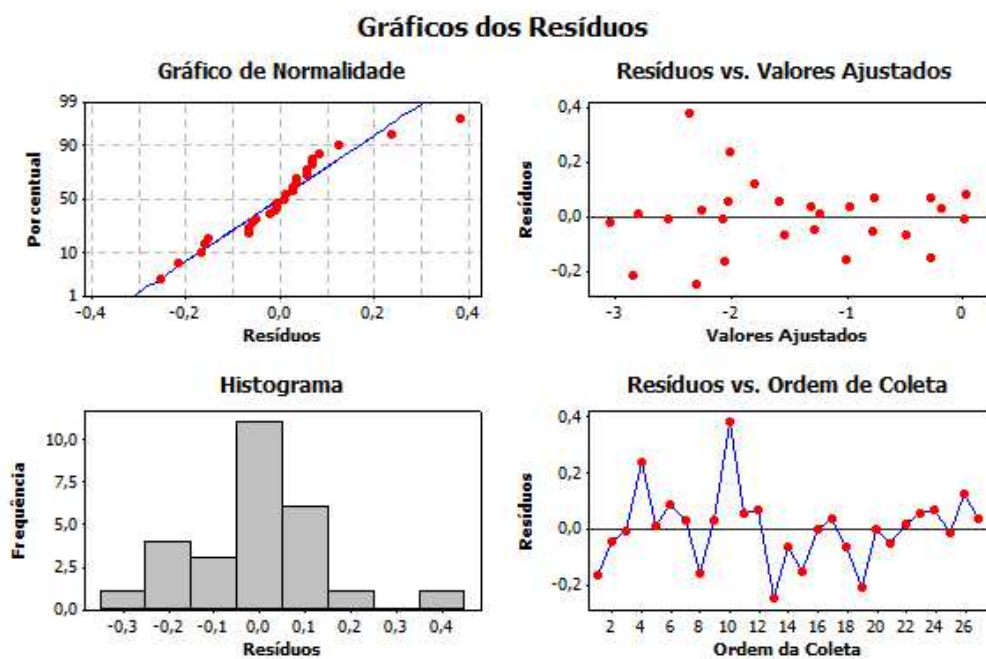


Figura A.2: Análise de resíduos do modelo ajustado (Fonte: MINITAB® 15)