

# BOLETIM APDIO

PUBLICAÇÃO SEMESTRAL | 64 | JUNHO '21

TÉCNICAS DE IO

**MACHINE LEARNING  
E OTIMIZAÇÃO:  
ALTERNATIVAS  
OU COMPLEMENTARES?**

ENTREVISTA

**PAOLO TOTH**

ARTIGO DE OPINIÃO

**MELHORAR AS CADEIAS  
DE ABASTECIMENTO VIA  
PROBLEMAS INTEGRADOS  
DE ROTEAMENTO DE VEÍCULOS**

IO EM AÇÃO

**OTIMIZAÇÃO DE ROTAS  
PERIÓDICAS  
NUM SERVIÇO DE APOIO  
DOMICILIÁRIO**

# ÍNDICE

03 ENTREVISTA  
PAOLO TOTH

05 ARTIGO DE OPINIÃO  
MELHORAR AS CADEIAS  
DE ABASTECIMENTO VIA  
PROBLEMAS INTEGRADOS  
DE ROTEAMENTO DE VEÍCULOS  
Bernardo Almada-Lobo  
Fábio Neves-Moreira  
Luís Guimarães

10 TÉCNICAS DE IO  
MACHINE LEARNING E OTIMIZAÇÃO:  
ALTERNATIVAS OU  
COMPLEMENTARES?  
Gonçalo Figueira  
Fábio Neves-Moreira

14 IO EM AÇÃO  
OTIMIZAÇÃO DE ROTAS PERIÓDICAS  
NUM SERVIÇO DE APOIO  
DOMICILIÁRIO  
Filipe Alves  
Filipe Alvelos  
Ana Maria A. C. Rocha

17 LUGAR AOS NOVOS  
PROBLEMAS DE ROTEAMENTO  
E ARMAZENAMENTO  
EM TRANSPORTE MARÍTIMO  
Filipe Rodrigues

19 O SÓCIO N.º...  
...1216  
Telmo Pinto

20 NOTÍCIAS DA APDIO



ELIANA COSTA E SILVA

Centro de Inovação e Investigação  
em Ciências Empresariais  
e Sistemas de Informação  
Escola Superior de Tecnologia e Gestão,  
Politécnico do Porto



RUI BORGES LOPES

Departamento de Economia,  
Gestão, Engenharia Industrial e Turismo.  
Universidade de Aveiro

## EDITORIAL

De entre os problemas clássicos de IO, o **Problema de Roteamento de Veículos** (PRV) está entre os que muito rapidamente se identificam aplicações no dia-a-dia de pessoas e instituições. De facto, a otimização do roteamento de veículos está no core da Logística e Gestão da Cadeia de Fornecimento, bem como das atividades associadas ao Transporte de Pessoas. Trata-se de uma área de investigação muito ativa em IO e que conta com uma vasta e intensa contribuição de um elevado número de académicos em instituições de ensino superior, centros de investigação e empresas. Este boletim começa com uma Entrevista a Paolo Toth, Professor Emeritus da Universidade de Bolonha, e um dos investigadores mais influentes na área do PRV. São referidas algumas oportunidades de investigação, reforçando a relevância do estudo dos problemas clássicos e como novos desafios na área podem ser tratados.

Em Artigo de Opinião, Bernardo Almada-Lobo, Fábio Neves-Moreira e Luís Guimarães fazem um enquadramento dos desafios atuais das cadeias de distribuição, no âmbito do PRV. De seguida, focam-se em dois problemas integradores: o problema de roteamento de inventário e o problema de roteamento da produção. Por último, apresentam algumas novas aplicações e tecnologias no âmbito destes problemas.

Na rubrica Técnicas de IO, Gonçalo Figueira e Fábio Neves-Moreira abordam Machine Learning (ML), classificando os principais paradigmas dos seus algoritmos. Posteriormente, abordam de que forma ML e IO podem ser usados em conjunto, finalizando com um exemplo no âmbito do retalho e apontando desafios futuros no ML.

Filipe Alves, Filipe Alvelos e Ana Maria Rocha apresentam, em IO em Ação, um exem-

plo de aplicação do PRV. No âmbito de um serviço de apoio domiciliário (de prestação de cuidados médicos, de enfermagem, ou sociais) pretendia-se determinar as rotas que os prestadores de serviço teriam que percorrer e qual o prestador que a iria percorrer, realizando os serviços associados. O objetivo era reduzir o comprimento total das rotas, garantindo que todos os serviços são satisfeitos.

Em Lugar aos Novos, Filipe Rodrigues aborda a aplicação do PRV no transporte marítimo. Inicialmente são apresentados os principais problemas de otimização, posteriormente releva a importância de aproximações integradas. O autor foca-se no problema de roteamento e armazenamento em transporte marítimo em contextos de incerteza.

Telmo Pinto, sócio número 1216, partilha connosco como tomou contacto e se interessou pela área de IO. Fala-nos, também, do subsequente percurso académico, e interesses e motivações atuais centrado em problemas integrados de otimização combinatória, com especial atenção ao setor da distribuição e em técnicas exatas e híbridas para a resolução desses problemas.

Na última página surge o espaço reservado às notícias relevantes para a comunidade de IO. Com o retorno das atividades presenciais, é dado um maior destaque a eventos que se irão realizar brevemente, em especial o IO2021!

# ENTREVISTA

**You have an impressive and diversified career. Can you give us an overview of your career, pointing the highlights and most deciding moments?**

I took a Master Degree in Electronic Engineering in February 1966 at the University of Bologna (Alma Mater Studiorum Università di Bologna, AD 1088). In the first 8 years of my research activity, I worked in the areas of *Computer Science* and *Automatic Control*. Only in the year 1975, I started to work on topics concerning the *Operational Research* (OR) area, and, in particular, on the definition of mathematical models and on the design of exact and heuristic algorithms for the solution of *Combinatorial Optimization* (CO) problems. It is to note that the Italian Universities started to offer Ph.D courses only in the year 1983, so I had no opportunity to obtain an Italian PhD Degree. I have a "Doctorate honoris causa" in OR conferred by the University of Montreal in the year 2003.

The first CO problems I tackled were:

- 1) the *Knapsack Problem* (KP) with Silvano Martello (previous Master Student of mine);
- 2) the *Asymmetric Traveling Salesman Problem* (ATSP) and the *Assignment Problem* (AP) with my colleague Giorgio Carpaneto;
- 3) the *Vehicle Routing Problem* (VRP) with Nicos Christofides (Imperial College, London) and Aristide Mingozzi (SOGESTA, Research Company of ENI, the main Italian Petrol Company "i"=>".").

The majority of the research results obtained in the following years, was mainly due to the tight and very fruitful collaboration with the previously mentioned colleagues and with

**"THE DIFFERENT VERSIONS OF THE CLASSICAL VRP ARE STILL WORTH TO BE STUDIED, SINCE THE BEST EXACT ALGORITHMS (...) REQUIRE LONG RUNNING TIMES TO SOLVE TO OPTIMALITY LARGE SIZED INSTANCES"**

the PhD students: Matteo Fischetti, Daniele Vigo, Alberto Caprara, Andrea Lodi, Juan José Salazar-Gonzalez, Michele Monaci, Enrico Malaguti, Valentina Cacchiani, Laura Galli, Andrea Tramontani, Albert E. Fernandes-Muritiba, Zahra Naji-Azimi, Majid Salari, Rosa Medina-Duran, Fabio Furini, Carlo Alfredo Persiani, Rodrigo Linfati, Roberto Roberti, John Wilmer Escobar-Velasquez, Eduardo Alvarez-Miranda, Carlos Contreras-Bolton, Carlos Rey.

In these years, I was involved in the solution of several variants and generalizations of the KP (mainly with Silvano Martello), of the ATSP (mainly with Matteo Fischetti and Juan José Salazar-Gonzalez) and of the VRP (mainly with Daniele Vigo). I also worked on the *Fixed Job Scheduling Problem* (with Silvano Martello and Matteo Fischetti), the *Set Covering Problem* (with Matteo Fischetti and Alberto Caprara), and the *Vertex Coloring Problem* (with Enrico Malaguti and Michele Monaci). In addition, we designed effective exact and heuristic algorithms for the solution of CO problems arising in real-world systems. Among these, I wish to mention:

- a) a "rich" VRP commissioned by ENI and concerning the optimization of the distribution of gasoline products from a central depot to a set of "gasoline stations" (this was the main reason for starting with Nicos Christofides and Aristide Mingozzi the study on the VRP family);
- b) a strong and fruitful collaboration with Pier Luigi Guida (*Rete Ferroviaria Italiana*, the main Italian Railway Infrastructure Manager company) for the solution of several real-world *Passenger Railway Optimization Problems: Crew Scheduling, Crew Rostering, Train Timetabling, Train Platforming, Train Unit Assignment* (joint research with Matteo Fischetti, Alberto Caprara, Daniele Vigo, Valentina Cacchiani, Laura Galli).

**Vehicle Routing Problems, which classically focus on cost minimization, have been increasingly incorporating several other characteristics and objectives (such as, CO<sub>2</sub> emission, equity, safety risks). From the practical point of view, do you feel that the classical single-objective cost minimization approach is still valid?**

The point raised by your question is



PAOLO TOTH

Professor Emeritus  
Università di Bologna  
paolo.toth@unibo.it



**“FOR THE MAJORITY OF THE REAL-WORLD VRP APPLICATIONS THE USE OF OPTIMIZATION ALGORITHMS, BOTH AT THE PLANNING AND THE OPERATIONAL LEVELS, LEADS TO SUBSTANTIAL SAVINGS IN THE GLOBAL TRANSPORTATION COSTS”**

important, since, in real-world systems, the VRP objectives may consider (according to a single-objective or a multi-objective model) several important goals, in addition to the global cost minimization and to the applications mentioned in your question. Possible examples are:

- a) when it is required to perform a selection among the customers to be serviced, the objective may include a profit component (to be maximized) for the visited customers;
- b) when the cost for employing drivers is relevant, the objective may include the route durations or the finishing times of the routes;
- c) when the customer satisfaction is taken into account, the objective may include a component depending on a latency term (given by the difference between the visiting times of the customers and their earliest possible service times);
- d) in humanitarian applications, in case of a disaster, the objective is to minimize the times at which the vehicles reach the affected areas;
- e) in perishable goods distribution, school bus routing and transportation of disabled persons, the objective is to minimize the duration that every request is on board a vehicle.

However, from the research point of view, my opinion is that the different versions of the classical VRP are still worth to be studied, since the best exact algorithms currently

published in the international literature for their solution (although very effective) require long running times to solve to optimality large sized instances.

**Which are, in your opinion, the main challenges or unaddressed real-world issues in the VRP literature?**

In most of the papers concerning the definition of mathematical models and the design of exact and metaheuristic algorithms for the solution of the classical VRP versions, the considered problem is assumed to be defined on an *undirected network*. In addition, for many benchmark instances it is assumed that the costs of the edges of the network are given by the Euclidean distances between the associated extreme nodes. However, these assumptions are not always satisfied in real-world applications, where the VRP instances to be solved are generally defined on *directed networks*, because of one way streets inside the urban areas, different slopes of the roads, etc.. As a consequence, it should be important to consider also the VRP versions defined on directed networks, and to introduce benchmark instances generated by considering real-world undirected and directed networks.

**There has been a significant shift of the transportation paradigms, partially due to the increase of e-commerce and home deliveries. New transportation modes, technologies and business models have forced practitioners to rethink their approaches. How do you see**

**researchers adapting to this shift, and how can the OR community contribute to it?**

My opinion is that the OR community can give a fundamental contribution to the new transportation requirements. Indeed, it has been clearly shown that for the majority of the real-world VRP applications the use of *optimization algorithms*, both at the planning and the operational levels, leads to substantial savings in the global transportation costs. This is due to the full integration of the information systems into the operational and commercial processes, and to the development and implementation of effective optimization algorithms, which are able to take into account all the characteristics of the VRP arising in real-world applications, so as to obtain high-quality feasible solutions within acceptable computing times. These optimization algorithms allow the planners to compare several different scenarios, and to choose the best one through a careful and fast evaluation of cost and service-related performance indicators. This feature is particularly important in applications concerning *e-commerce*, *home deliveries* and *online services*, where it is required a fast reaction of the planner to the dynamics of the transportation system and of the customers requests, and also to the possible disruptions caused by the failure of vehicles or by heavy traffic conditions. Of course, online optimization tools are compulsory for real-time applications such as the control of automatic guided vehicles.

# MELHORAR AS CADEIAS DE ABASTECIMENTO VIA PROBLEMAS INTEGRADOS DE ROTEAMENTO DE VEÍCULOS

## ENQUADRAMENTO DOS DESAFIOS DA CADEIA DE ABASTECIMENTO

Tipicamente, as cadeias de abastecimento incluem atividades de produção, gestão de inventário e distribuição (transportes), que são planeadas ao nível estratégico, tático e operacional. Estas atividades estão ancoradas em diferentes equipas que exercem o melhor dos seus esforços na busca de soluções (planos) satisfatórias, num processo de tomada de decisão sequencial. Exemplificando, a elaboração dos planos de produção precede (e restringe) a dos planos de distribuição. Os silos organizacionais e os processos de tomada de decisão descentralizados levam a que, no melhor dos cenários, sejam atingidos ótimos locais para cada um dos domínios funcionais referidos anteriormente. Fruto da promessa de poupanças significativas, investigadores e *practicioners* têm-se dedicado ao planeamento integrado de várias atividades da cadeia de abastecimento em diferentes contextos do mundo real. Os investigadores, movidos pelo desafio de atacar problemas mais complexos, que exijam abordagens mais musculadas e sofisticadas, com maior potencial de publicação; os *practicioners*, pela necessidade de aumento da eficiência das operações internas das suas organizações. Recentemente, os avanços tecnológicos ao nível do poder computacional, levaram a um aumento exponencial do interesse por planeamento integrado. Urge, no entanto, o desafio (e quiçá

**“FRUTO DA PROMESSA DE POUPANÇAS SIGNIFICATIVAS, INVESTIGADORES E PRACTICIONERS TÊM-SE DEDICADO AO PLANEAMENTO INTEGRADO DE VÁRIAS ATIVIDADES DA CADEIA DE ABASTECIMENTO EM DIFERENTES CONTEXTOS DO MUNDO REAL”**

a arte) de saber o que integrar, designadamente os elos/atividades da cadeia a selecionar (designada por integração horizontal) e/ou os diferentes níveis de planeamento (integração vertical). Em honra ao tema do atual Boletim, debruçar-nos-emos sobre a integração do problema de roteamento de veículos com outras atividades funcionais da cadeia.

Nas secções seguintes, apresentaremos dois dos problemas de roteamento integrado mais estudados, tecendo considerações sobre as técnicas de modelação, o valor da integração e alguns desafios encontrados na prática. Concluiremos esta exposição apresentando aplicações e tecnologias que deverão impactar o futuro do planeamento integrado.

## ROTEAMENTO DE INVENTÁRIO

O problema de roteamento de inventário (IRP) [3] é uma extensão do problema clássico de roteamento de veículos (VRP), integrando e coordenando a gestão de transportes com a gestão de inventário. Tipicamente, entidades cujo processo de planeamento exige a resolução de um IRP operam com base numa política de inventário totalmente gerido pelo fornecedor (designado por VMI - *Vendor Managed Inventory*). Neste tipo de políticas, as decisões de gestão de inventário são centralizadas numa entidade (ex. fornecedor), que define os níveis de inventário de um conjunto de localizações (ex. retalhistas) e as rotas de distribuição a realizar por uma frota de veículos. O planeamento define: (1) quando devem realizar-se entregas a cada localização de inventário; (2) qual deverá ser a quantidade a enviar a cada localização de inventário; e (3) qual deverá ser a sequência de entregas, isto é, as rotas de distribuição a realizar por cada veículo em cada período (ex. dia). O objetivo é satisfazer a procura das diferentes localizações de inventário, minimizando o custo global, que contempla os custos de transporte e de armazenagem. As reduções de custo decorrentes desta integração poderão estar compreendidas entre 6% e 10% [3].

Não obstante a complexidade inerente a um problema tão abrangente, vários artigos científicos têm-se debruçado sobre extensões do IRP que o tornem aplicável em diversos contextos



**BERNARDO ALMADA-LOBO**

INESC TEC,  
Faculdade de Engenharia,  
Universidade do Porto  
almada.lob@fe.up.pt



**FÁBIO NEVES-MOREIRA**

INESC TEC,  
Faculdade de Engenharia,  
Universidade do Porto  
fabio.s.moreira@inectec.pt



**LUÍS GUIMARÃES**

INESC TEC,  
Faculdade de Engenharia,  
Universidade do Porto  
guimaraes.luis@fe.up.pt



Fig. 1 - Aplicações reais do IRP e principais desafios de modelação.

[5]. Alguns exemplos podem ser encontrados no setor das máquinas de vending, no abastecimento de caixas de multibanco, na recolha de amostras de sangue, no retalho de moda e, mais recentemente, no reposicionamento de bicicletas ou trotinetes elétricas (ver Fig. 1). Para modelar um IRP através de um modelo de programação linear inteira mista (MIP),  $G=(N,A)$  considere-se um grafo em que o conjunto de vértices  $N=\{0,1,\dots,n\}$  é dividido no vértice 0 que representa o fornecedor que atua como um depósito de veículos, e nos vértices  $\{0,1,\dots,n\}$ , que correspondem a  $n$  localizações de inventário a servir. Cada arco  $(i,j) \in A$  está associado a um custo de transporte  $c_{ij}$ . Os produtos podem ser armazenados nas localizações de inventário, incorrendo-se num custo de stock  $h_i$  por cada unidade armazenada na localização  $i$  em cada período. O nível de inventário de cada localização deve ser mantido entre um limite inferior e um limite superior definidos pelo intervalo  $[L_i, U_i]$ . O fornecedor dispõe de uma frota de veículos com capacidade  $C$  para realizar as entregas e, em cada período  $t \in T$ , disponibiliza uma quantidade de produto adicional dada por  $p_{0t}$ . Cada localização de inventário  $i$  deve

satisfazer a procura do cliente final  $d_{it}$  em cada período  $t$ . Na Fig. 2 apresenta-se o exemplo de uma rota que sai de um centro de distribuição e serve um conjunto de clientes.

Com base nos parâmetros apresentados, podemos descrever um modelo IRP considerando um ou mais veículos, um ou mais produtos e um horizonte de planeamento finito constituído por um conjunto de períodos. O modelo recorre a variáveis binárias  $X$  e  $Z$  para modelar as decisões de roteamento dos veículos:  $X$  indicam se o arco  $(i,j)$  é percorrido no período  $t$ ;  $Z_{it}$  se a localização  $i$  é visitada no período  $t$ . Adicionalmente, as variáveis contínuas  $I_{it}$  e  $D_{it}$  definem as quantidades de inventário e de entrega por localização  $i$  e período  $t$ .

As decisões de modelação são extremamente importantes no contexto do IRP. Por um lado, considerar maior detalhe poderá facilitar a execução das operações através de um planeamento mais realista, capaz de otimizar corretamente os objetivos pretendidos. Por outro lado, extensões ao IRP rapidamente tornam os modelos intratáveis, exigindo técnicas de otimização avançadas que extravasam a simples utilização de um solver matemático comercial.

Daí que a aplicação num contexto real de um modelo de IRP requiera a resposta a algumas questões.

Primeiro, importa definir o conjunto de parâmetros do modelo que "melhor" retrata o negócio e o problema que se pretende resolver. Por exemplo, a granularidade das previsões da procura ou a duração das rotas podem ser bons indicadores para a definição do período a considerar no modelo (dia completo? parte do dia?). Adicionalmente, deve ser questionada a necessidade de considerar modelos multi-produto no caso de existirem diferenças consideráveis em consumos de recursos ou custos incorridos entre produtos. Por exemplo, na presença de restrições de janelas de entrega, se um determinado produto demorar mais tempo a ser descarregado, poderá ser importante modelar tempos de descarga dependentes do produto. Outra questão pertinente prende-se com o detalhe da frota a considerar. No caso de a frota possuir veículos com características distintas e de existirem restrições que limitem a utilização de certos veículos em determinadas situações (pela tipologia de produtos e/ou por restrições de acessibilidade), a modelação de IRP com frota heterogénea torna-se vital.

Segundo, o modelo de IRP deve adaptar-se ao processo de planeamento. Quantos períodos devem ser considerados em cada iteração de planeamento? Claro que quanto maior o seu número, mais difícil se torna a resolução de cada iteração. Note-se que a frequência das iterações de planeamento deve ser ajustada de acordo com o dinamismo de cada negócio. A título de exemplo, um planeador que resolva um IRP com cinco períodos, pode replanear a operação no final de cada dia, já que é provável que obtenha nova informação para melhorar o planeamento dos dias seguintes. Em alguns contextos de negócio pode não ser possível replanear diariamente, tendo o planeador de adotar um procedimento assente em iterações de planeamento menos frequentes.

Terceiro, deve ser avaliada a necessidade de considerar incerteza e, conseqüentemente, modelos de programação estocástica ou robusta. Quanto mais longos forem os horizontes de planeamento, maior a pertinência deste tipo de abordagens. Uma das técnicas de modelação que pode ser adotada nestes casos consiste na inclusão de um conjunto de cenários, cada

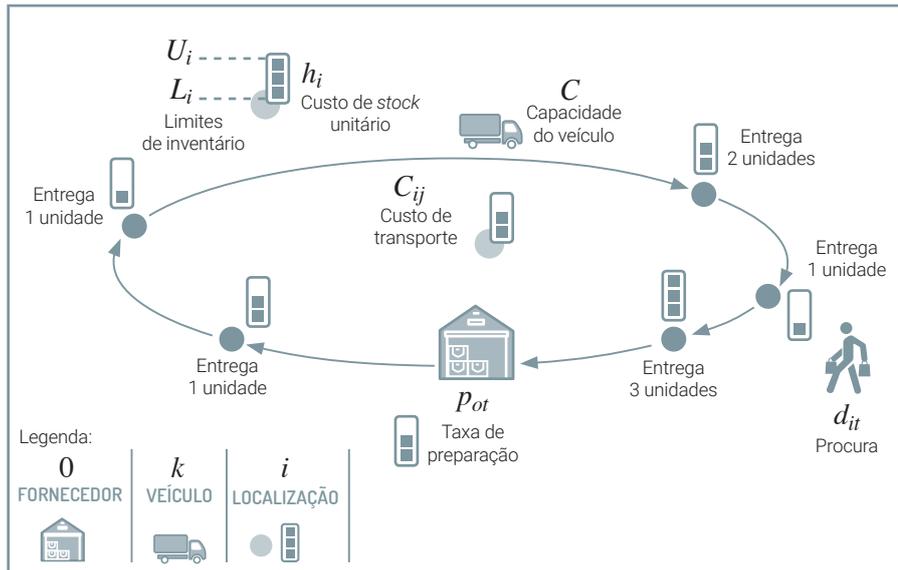


Fig. 2 - Exemplo de uma rota num período de um IRP.

um com diferentes parâmetros do negócio (ex. diferentes procuras). Tipicamente, estes modelos são utilizados em problemas com decisões de âmbito mais alargado (ex. táticas ou estratégicas), para obter soluções que ofereçam estabilidade em determinada dimensão de planeamento. Por exemplo, IRP estocásticos podem ser utilizados no sentido de perceber qual a “melhor” frota a utilizar nos próximos anos, quais as “melhores” localizações para os depósitos de veículos, ou até qual o “melhor” mix de produtos a oferecer.

### ROTEAMENTO DA PRODUÇÃO

O problema de roteamento da produção (PRP) combina dois problemas clássicos da investigação operacional: o problema de dimensionamento de lotes (LSP) [8] e o problema de roteamento de veículos (VRP) [6]. O PRP é uma extensão do IRP, dado que as quantidades disponibilizadas pelo fornecedor estão dependentes de decisões de produção. Sempre que em determinado período se produz uma quantidade, incorre-se num custo de preparação do equipamento de produção - custo de *setup*. O objetivo é minimizar o custo global do sistema que é composto por custos de produção, inventário e transporte. No fundo, procura-se um compromisso entre o número de *setups* na produção e o número de visitas aos pontos

de venda, equilibrando quantidades de *stock* e de entrega. A Fig. 3 representa um exemplo de um PRP considerando decisões de produção, inventário e roteamento.

Naturalmente, os modelos de PRP requerem um esforço enorme em termos de parametrização. Para além de todos os parâmetros considerados no IRP, é necessário considerar parâmetros relacionados com a atividade de produção, como os custos e tempos de *setup* dos equipamentos de produção.

Não obstante os desafios de implementação, o PRP é conhecido pelo seu enorme potencial no que diz respeito a melhorias em indicadores da cadeia de abastecimento e, conseqüentemente, reduções de custo global. Tipicamente, a literatura reporta reduções no custo global de 3% a 20% [4]. As categorias de custo mais impactadas estão muito dependentes do negócio, isto é, da relação intrínseca entre custos de produção, *stock* e transporte. Em sistemas com a participação de várias entidades independentes, este facto pode levantar questões complexas de governança pois pode não ser trivial “convencer” uma determinada entidade de que os custos de outra entidade vão ser parcialmente transferidos para si, em prol do custo global. Independentemente de todas as exigências técnicas, este tipo de modelos tem um enorme potencial de aplicação prática e tem sido largamente explorado nos últimos anos [2].

“O PRP [PROBLEMA DE ROTEAMENTO DA PRODUÇÃO] É CONHECIDO PELO SEU ENORME POTENCIAL NO QUE DIZ RESPEITO A MELHORIAS EM INDICADORES DA CADEIA DE ABASTECIMENTO E, CONSEQUENTEMENTE, REDUÇÕES DE CUSTO GLOBAL. TÍPICAMENTE, A LITERATURA REPORTA REDUÇÕES NO CUSTO GLOBAL DE 3% A 20%”

Para modelar um PRP, introduzem-se variáveis de decisão relacionadas com o ambiente produtivo: as variáveis binárias  $B_t$  que indicam se o fornecedor realiza um *setup* no período  $t$ ; as variáveis contínuas  $P_{ot}$  que definem a quantidade produzida pelo fornecedor no período  $t$ .

As formulações de PRP podem considerar um ou mais tipos de veículos e/ou tipos de produto, e apresentar outras restrições que emergem da aplicação. A título de exemplo, num problema de produção de carnes para abastecimento de talhos é necessário considerar tempos de preparação das linhas de corte por produto e por família de produto, restringir a quantidade mínima de cada lote de produção, garantir o cumprimento de restrições de perecibilidade e forçar o cumprimento das janelas de entrega de cada talho. A Fig. 4 apresenta as várias etapas que foram modeladas no problema atacado em [7].

Mais uma vez, a complexidade dos problemas de roteamento integrado está sempre associada a um “preço a pagar” nos métodos de resolução. Para resolver o PRP apresentado, foi necessário propor técnicas de decomposição que permitissem otimizar subconjuntos de variáveis iterativamente. De facto, dada a complexidade do problema e a dimensão das instâncias reais, os *solvers* comerciais são insuficientes para resolver estes modelos.

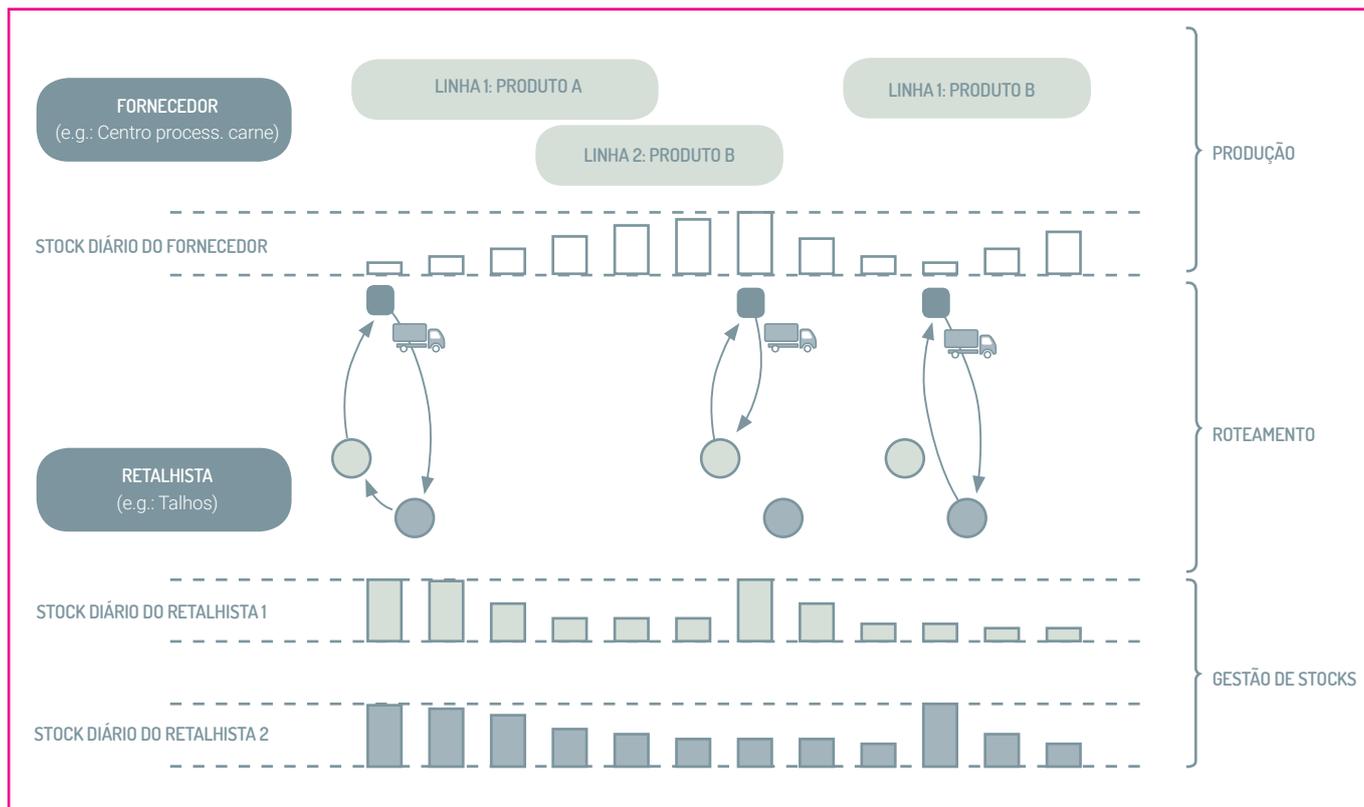


Fig. 3 - Exemplo das decisões de produção, inventário e transportes inerentes a um PRP.

Apesar da complexidade e da exigência das técnicas de otimização necessárias, a modelação do PRP apresenta um enorme potencial de melhoria dos indicadores operacionais. Esta melhoria advém da pesquisa de um espaço de solução de maiores dimensões, que integra todas as decisões num modelo holístico, o que não acontece quando resolvemos o problema de produção e transportes sequencialmente. Além disso, não é desprezável o valor que um modelo de otimização oferece em termos de possibilidades de análise de sensibilidade. A complexidade do PRP impossibilita a produção de conclusões de forma manual, sendo absolutamente indispensável deter um modelo que avalie os impactos decorrentes da alteração de determinados parâmetros de planeamento. A título de exemplo, é possível quantificar o valor de considerar horizontes de planeamento mais longos [7] e/ou quantificar o valor de um processo de planeamento holístico em comparação a um processo sequencial [1].

#### NOVAS APLICAÇÕES E TECNOLOGIAS – FUTURO DO IRP E PRP

Ao longo deste artigo, focámos a exposição em problemas e abordagens clássicas da literatura de IRP e PRP. A maior parte destas abordagens ainda não tira partido de tecnologias recentes que poderão revolucionar o universo dos problemas de transporte integrado.

**Inteligência artificial.** É inegável que a inteligência artificial assumirá um papel preponderante na economia mundial. Apesar de a maior parte das suas aplicações em produção se focarem em problemas descritivos (ex. *unsupervised learning*) e preditivos (ex. *supervised learning*), esta tecnologia tem enorme potencial na resolução de problemas prescritivos (ex. *reinforcement learning* e *neural combinatorial optimization*). Estas abordagens permitirão alavancar grandes quantidades de dados e simplificar os problemas de otimização inerentes a problemas de transporte integrado, identificando quais as decisões que são sub-ótimas no

imediatamente, mas que poderão significar ganhos futuros mais elevados.

**Internet das coisas.** O planeamento integrado exige uma quantidade considerável de dados. Todos sabemos a dificuldade que existe em recolher dados de qualidade com a granularidade necessária. O conceito de internet das coisas terá um papel preponderante no desenvolvimento de abordagens integradas pois permitirá que os próprios equipamentos de produção (ex. máquinas e veículos) forneçam dados de maior qualidade e em tempo real. Esta disponibilidade de dados aliada a uma quantidade considerável de sensores capazes de detetar eventos e acionar *triggers* associados ao equipamento de produção abrirá inúmeras possibilidades em termos de abordagens de planeamento.

**Blockchain.** Uma das dificuldades na implementação de sistemas integrados prende-se com as questões de governança, principalmente quando existem várias entidades com objetivos individuais que competem entre si. A

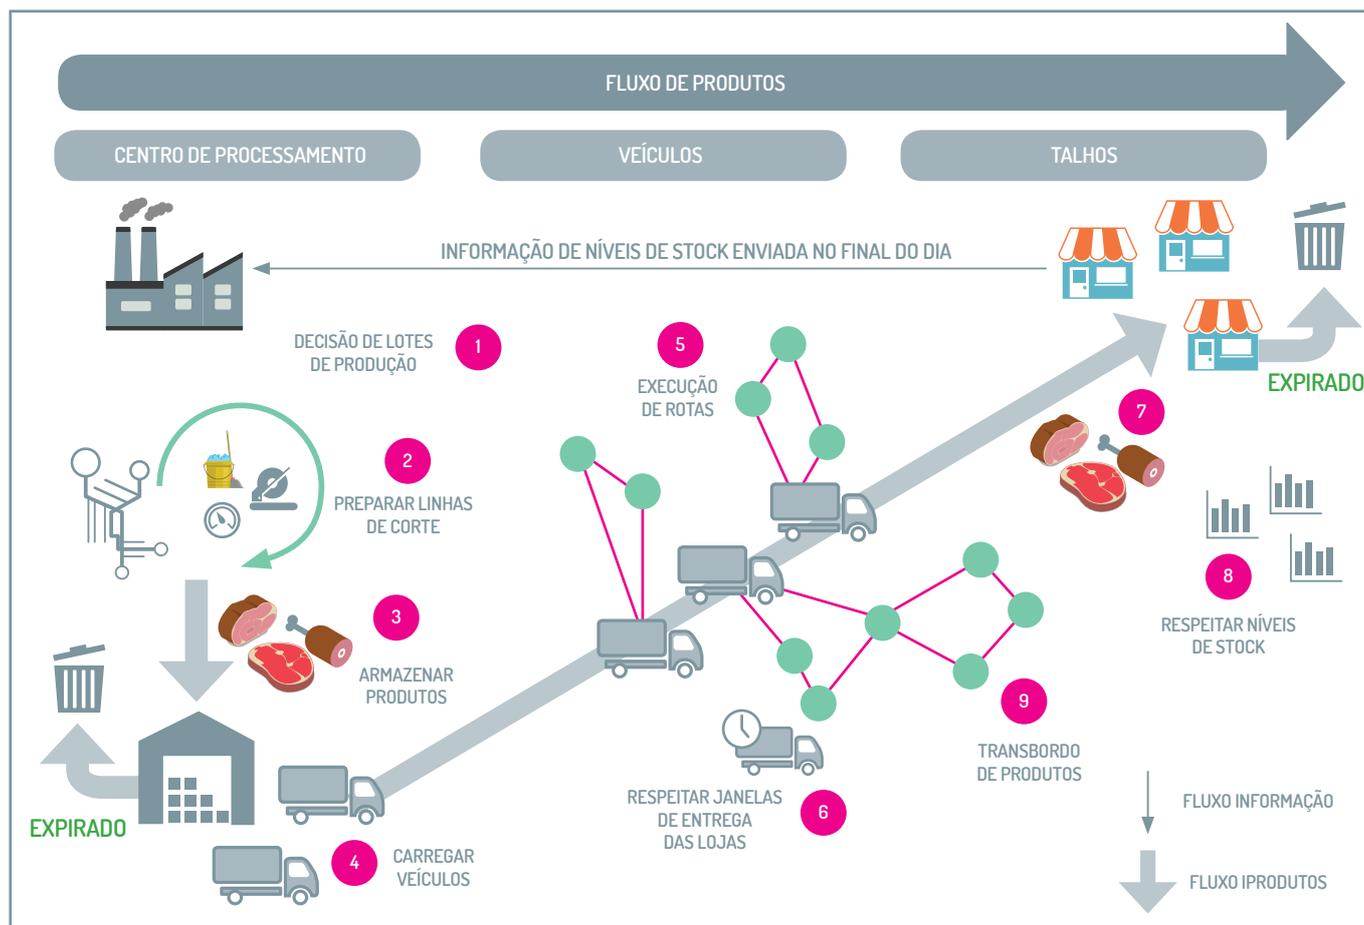


Fig 4 - Exemplo de um PRP resolvido no contexto real de um retalhista alimentar. O objetivo é dimensionar os lotes de produção (corte de carne), definir as rotas de entrega (talhos de hipermercados) e equilibrar os níveis de stock, minimizando o custo global.

definição de regras de governança ou contratos inteligentes poderá trazer novas possibilidades ao planeamento baseado em IRP e PRP. O facto de se conseguir implementar regras de consenso de uma rede (ex. uma rede de retalhistas geridos por entidades distintas) abrirá portas para

novos modelos de gestão e colaboração. Por exemplo, será possível definir DAO (*Decentralized Autonomous Organizations*) onde os participantes terão de cumprir regras (ex. garantir sustentabilidade ambiental) para usufruir de determinados serviços (ex. usufruir de planeamento integrado).

Estas tecnologias foram pouco exploradas no contexto do IRP e do PRP. Será extremamente interessante assistir ao desenvolvimento e aplicação de novas abordagens fazendo uso destes conceitos, permitindo melhorias de eficiência em vários sectores e negócios.

#### REFERÊNCIAS

- [1] Absi, N., Archetti, C., Dauzère-Pérès, S., Feillet, D., & Speranza, M.G. (2018). Comparing sequential and integrated approaches for the production routing problem. *European Journal of Operational Research*, 269(2):633–646.
- [2] Adulyasak, Y., Cordeau, J.-F., and Jans, R. (2015). The production routing problem: A review of formulations and solution algorithms. *Computers & Operations Research*, 55:141–152.
- [3] Bell, W., Dalberto, L., & Fisher, M. (1983). Improving the distribution of industrial gases with an on-line computerized routing and scheduling optimizer. *Interfaces*, 13(6):4–23.
- [4] Chandra, P. & Fisher, M.L. (1994). Coordination of production and distribution planning. *European Journal of Operational Research*, 72(3):503–517.
- [5] Coelho, L.C., Cordeau, J.-F., & Laporte, G. (2014). Thirty years of inventory routing. *Transportation Science*, 48(1):1–19.
- [6] Dantzig, G.B. & Ramser, J.H. (1959). The Truck Dispatching Problem. *Management Science*, 6(1):80–91.
- [7] Neves-Moreira, F., Almada-Lobo, B., Cordeau, J.-F., Guimarães, L., & Jans, R. (2019). Solving a large multi-product production-routing problem with delivery time windows. *Omega*, 86:154–172.
- [8] Wagner, H.M. & Whitin, T.M. (1958). Dynamic version of the economic lot size model. *Management science*, 5(1):89–96.

# MACHINE LEARNING E OTIMIZAÇÃO: ALTERNATIVAS OU COMPLEMENTARES?



GONÇALO FIGUEIRA

INESC TEC, Faculdade de Engenharia,  
Universidade do Porto,  
lfigueira@fe.up.pt



FÁBIO NEVES-MOREIRA

INESC TEC, Faculdade de Engenharia,  
Universidade do Porto,  
fabio.s.moreira@inesctec.pt

“Os dados são o novo petróleo” e o *Machine Learning* (ML) tem-se revelado, por excelência, a área que melhor aproveita este recurso. De uma forma geral, o ML consiste na utilização de um algoritmo para aprender ou generalizar a identificação de padrões e/ou tomada de decisão a partir de um conjunto de dados históricos. O processo de aprendizagem de uma abordagem de ML está intimamente relacionado com a forma como os humanos aprendem, através de exemplos e experiências que gradualmente os ajudam a melhorar a qualidade e precisão das tarefas que realizam. Estas tarefas são, no fundo, aproximações de funções que mapeiam entradas de dados (*inputs*) em determinados resultados (*outputs*).

Quando falamos em ML, podemos referir-nos a aplicações muito diferentes e que trabalham com formatos diferentes de dados (p.ex. classificação de imagens, reconhecimento de voz, processamento de linguagem natural, etc.), conduzindo naturalmente a técnicas distintas. No âmbito deste artigo, focar-nos-emos no formato mais tradicional de dados tabulares.

Os algoritmos de ML podem ser classificados em três paradigmas de aprendizagem: supervisionada, não-supervisionada e de políticas. Estes três paradigmas estão intimamente ligados às três camadas típicas do *Analytics*: descritiva, preditiva e prescritiva (ver Fig. 1). A Otimização, que é conhecida como a abordagem natural para problemas prescritivos, está na verdade também na base das técnicas usadas nos restantes paradigmas. Respondendo à questão do título deste artigo, ML e Otimização são paradigmas usados em problemas diferentes, mas há também uma relação estreita entre ambos e sinergias a serem exploradas. Antes de introduzir esses temas, comecemos por uma breve apresentação de cada um dos paradigmas.

**Aprendizagem Supervisionada** Dado um conjunto de dados  $D = \{(x_1, y_1), \dots, (x_N, y_N)\} \subseteq \mathbb{R}^M \times \mathcal{C}$ , onde  $N$  é o número de observações,  $x_i$  o vetor de atributos (de dimensão  $M$ ) da  $i$ -ésima observação, e  $y_i$  a etiqueta correspondente (sendo  $\mathcal{C}$  o seu domínio), o objectivo é encontrar a função  $f: \mathbb{R}^M \rightarrow \mathcal{C}$  tal que para novos pares  $(x, y)$  se tenha  $f(x) \approx y$ . Trata-se, portanto, de tarefas de regressão ou classificação (usando regressão linear, regressão logística, redes neuronais, *random forests*, *support vector*

*machines*, etc.), para resolver essencialmente problemas preditivos. Este paradigma também é usado por vezes em problemas prescritivos, onde para cada instância  $i$  se tem quer os seus atributos  $(x_i)$ , quer uma solução de elevada qualidade [7]. No entanto, o sucesso desta abordagem depende de encontrar os atributos certos que permitam aprender uma função  $f$  que consiga generalizar devidamente.

**Aprendizagem Não-Supervisionada** Não dispondo de etiquetas nos dados de entrada, o objetivo neste caso passa por tentar aprender a distribuição de probabilidade do vetor de atributos  $x$  ou propriedades relevantes dessa distribuição. Trata-se, portanto, de descrever o conjunto de dados, agregando ou sumariando a informação nele contida, através por exemplo de agrupar as observações com base nos seus atributos (o chamado *clustering* - usando algoritmos como k-means), encontrando relações (com regras de associação), ou construindo novos atributos para reduzir a dimensão do espaço (com métodos como a análise de componentes principais).

**Aprendizagem de Políticas** Considere-se um sistema dinâmico descrito por um estado  $S_t$ , onde se realiza uma ação  $x_t = X^\pi(S_t)$  (de acordo com uma política  $\pi \in \Pi$ ), se observa nova

**“NOS ÚLTIMOS ANOS, ESTA HIBRIDIZAÇÃO [ENTRE ML E ABORDAGENS DE OTIMIZAÇÃO] TEM INUNDADO TANTO BLOGS COMO REVISTAS CIENTÍFICAS COM NOVAS ABORDAGENS QUE PROMETEM ACELERAR OS MÉTODOS DE OTIMIZAÇÃO TRADICIONAIS E TORNÁ-LOS MAIS PREPARADOS PARA PROBLEMAS MAIS DINÂMICOS OU COM VÁRIAS FONTES DE INCERTEZA”**



É frequente utilizar métodos de otimização simples (como a pesquisa aleatória ou a pesquisa em grelha), bem como métodos mais sofisticados (como a otimização bayesiana), que fazem uma aproximação da função por forma a poupar esforço computacional.

As tarefas de Aprendizagem Não-Supervisionada estão geralmente associadas a agregação de informação, seja pela identificação de características comuns, seja pela projeção das dimensões em espaços menores. Tal como na Aprendizagem Supervisionada, o problema de otimização pode ser formulado como minimização de uma função perda (aplicando-se os mesmos métodos de otimização não-linear referidos acima), mas neste caso sem etiquetas. Exemplificam-se aqui duas tarefas fundamentais:

- Clustering - onde se pretende encontrar grupos de observações, garantindo que as diferenças entre as observações de cada grupo são tão pequenas quanto possível. O problema consiste em minimizar a seguinte função perda (em termos da norma euclidiana quadrática):

$$\min_s \sum_{k=1}^K \sum_{x \in S_k} \|x - \mu_k\|_2^2,$$

em que  $K$  é o número de grupos,  $x$  é o vetor de observações,  $\mu_k$  é o centro do grupo  $k$ , e  $S_k$  é o conjunto de observações pertencentes ao grupo  $k$ .

- Extração de atributos - à semelhança da seleção de atributos (ver acima), pretende-se reduzir a dimensionalidade do espaço de atributos. Mas enquanto no primeiro caso se seleciona um subconjunto dos atributos existentes, aqui são construídos novos atributos. Através da análise de componentes principais (PCA), podemos reduzir a dimensão de uma observação garantindo que a informação original é mantida, tanto quanto possível, após ser projetada para um espaço dimensional menor. Neste caso, o objetivo é minimizar o erro obtido na reconstrução da informação original:

$$\min \sum_{i=1}^N \|\bar{x}_i - x_i\|_2^2,$$

onde  $N$  é o número de observações,  $x_i$  é um vetor de  $M$  dimensões,

$$\bar{x}_i = \sum_{j=1}^{M'} z_{ij} e_j$$

é uma reconstrução de  $x_i$ ,  $z_{ij} = \{z_{i1}, \dots, z_{iM'}\}$  é a projeção de  $x_i$  no espaço de dimensão  $M'$

( $M' \gg M$ ), e  $e_j$  é a base ortonormal do mesmo espaço.

Finalmente, na Aprendizagem de Políticas, a Otimização assume naturalmente um papel importante, dada a complexidade desses algoritmos. Dependendo da abordagem e do algoritmo em concreto, haverá parâmetros muito diversos a otimizar. No caso, por exemplo, de Reinforcement Learning, há uma série de parâmetros e hiperparâmetros, que podem ser determinados recorrendo a otimização não-linear [10]. Já na Programação Genética, a própria pesquisa das expressões analíticas é realizada por algoritmos evolucionários [3].

#### MACHINE LEARNING AO SERVIÇO DA OTIMIZAÇÃO

Debrucemo-nos agora sobre o papel do ML em abordagens de otimização. Nos últimos anos, esta hibridização tem inundado tanto blogs como revistas científicas com novas abordagens que prometem acelerar os métodos de otimização tradicionais e torná-los mais preparados para problemas mais dinâmicos ou com várias fontes de incerteza, tirando partido da grande quantidade de dados disponíveis atualmente. É de facto uma promessa forte que se tem materializado em inúmeras abordagens com diferentes propósitos.

Num projeto típico de otimização tomam-se várias decisões relacionadas com o desenho do algoritmo de otimização. De modo geral, é comum haver a necessidade de se escolher o tipo de algoritmo, a função de avaliação de soluções e um processo de melhoria de soluções [2]. A comunidade de ML tem contribuído com melhorias em cada um dos processos típicos de um projeto de otimização:

- Seleção de algoritmos e definição de modelos - Podemos olhar para a seleção de um algoritmo de otimização como um problema de otimização em si mesmo. Visto que as técnicas de ML são capazes de prever o desempenho de um algoritmo de otimização sem ser necessário correr esse algoritmo, é possível obter soluções com boa qualidade com um tempo computacional desprezável (depois de treinadas). Além disso, também é possível ajustar ou controlar os parâmetros dos algoritmos de otimização com base num histórico de corridas.

- Estimativa de funções de avaliação - Por vezes, a avaliação de uma solução de um problema de otimização pode ser computacionalmente complexa. Como tal, este é outro caso em que as técnicas de ML podem ajudar a estimar o valor de uma solução, acelerando o processo de pesquisa inerente a um determinado algoritmo de otimização, visto que é necessário avaliar bastantes soluções ao longo de cada corrida.

• Melhoria da pesquisa - Naturalmente, os processos de pesquisa onde se procuram melhorias em soluções incumbentes podem ser melhorados utilizando técnicas de ML que selecionem bons operadores que alterem a solução no sentido de a melhorar. Por exemplo, o conhecido *trade-off* entre exploração e intensificação pode ser analisado de modo a permitir seleções de operadores que não sejam totalmente gulosos, considerando os impactos futuros das decisões imediatas.

Há ainda vários desafios que a comunidade de otimização gostaria de resolver, principalmente no que diz respeito a métodos exatos. Que variáveis escolher no processo de *branching* de um algoritmo de *branch-and-bound*? Que tipo de cortes introduzir em cada fase de um algoritmo de *branch-and-cut*? Que colunas adicionar em cada fase de um algoritmo de *branch-and-price*? Estas são perguntas às quais as comunidades de ML e otimização tentam agora responder num tremendo exercício de cooperação. Enquanto não provarmos que  $P=NP$  ou enquanto não encontramos o caminho para a inteligência artificial geral, faz todo o sentido continuar a propor pequenas melhorias que nos permitam resolver problemas mais complexos e de maior dimensão em tempo útil.

Há ainda vários desafios que a comunidade de otimização gostaria de resolver, principalmente no que diz respeito a métodos exatos. Que variáveis escolher no processo de *branching* de um algoritmo de *branch-and-bound*? Que tipo de cortes introduzir em cada fase de um algoritmo de *branch-and-cut*? Que colunas adicionar em cada fase de um algoritmo de *branch-and-price*? Estas são perguntas às quais as comunidades de ML e otimização tentam agora responder num tremendo exercício de cooperação. Enquanto não provarmos que  $P=NP$  ou enquanto não encontramos o caminho para a inteligência artificial geral, faz todo o sentido continuar a propor pequenas melhorias que nos permitam resolver problemas mais complexos e de maior dimensão em tempo útil.

#### MACHINE LEARNING PARA ROTEAMENTO DE VEÍCULOS

Em honra ao tema do atual Boletim, apresentamos alguns desafios que a comunidade de roteamento de veículos (VRP) tem atacado através de ML. O VRP é um dos problemas mais difíceis em investigação operacional e, nesse sentido, a comunidade científica tem utilizado técnicas de ML para conseguir obter os tempos de execução típicos de regras simples e soluções com a qualidade típica de métodos sofisticados.

Para ilustrar os desafios de um projeto de roteamento atual vamos focar-nos no exemplo de um retalhista que opera uma plataforma online onde os clientes podem realizar compras e

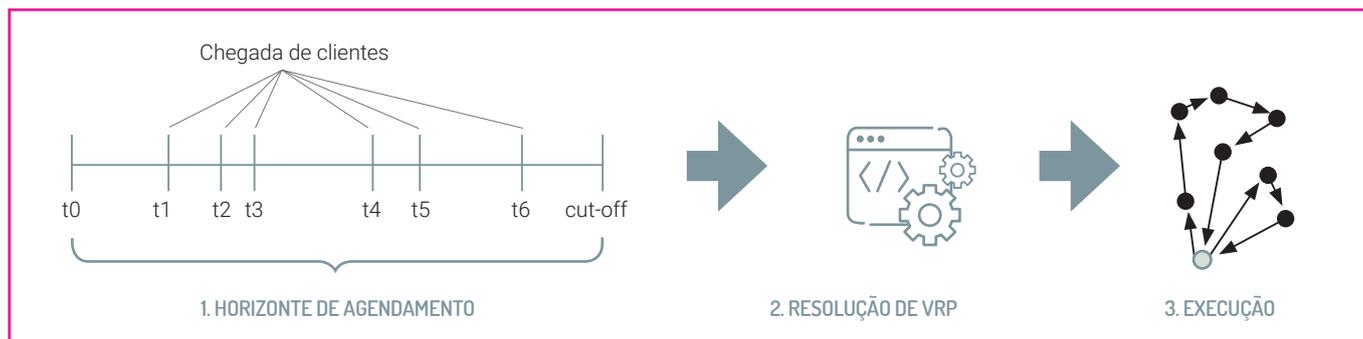


Fig. 2 - Exemplo de uma atividade de agendamento de entregas.

agendar uma entrega. O retalhista deve analisar a sua capacidade em termos de recursos logísticos e mostrar aos clientes um preço de entrega para cada janela de entrega. (1) Se for muito alto, os clientes podem cancelar a compra, (2) se for muito baixo, o retalhista pode incorrer num prejuízo. Após o fecho do horizonte de agendamento, as entregas são planeadas para posterior execução no terreno (Fig. 2).

O retalhista poderia resolver um VRP sempre que um novo cliente chegasse à plataforma de forma a estimar um custo de inserção. Seria necessário resolver um VRP para cada janela de entrega disponível, visto que o custo de inserção depende da janela de entrega e o retalhista pretende definir um preço para cada janela que garanta lucro. Não podemos esquecer que este cálculo deve ser feito em frações de segundo para não comprometer a experiência de compra do cliente. Mesmo que os VRP sejam resolvidos de forma aproximada, a utilização de métodos de otimização clássicos torna-se pouco viável.

Esta árdua tarefa computacional pode ser evitada estimando o custo de inserção de um novo cliente utilizando ML. Se treinarmos um algorit-

mo capaz de estimar este custo tendo em conta o estado atual dos recursos (p.ex. capacidade restante nos veículos, encomendas aceites, etc.) e as particularidades desse cliente (p.ex. localização, *willingness-to-pay*, etc.), podemos evitar a resolução de um VRP para cada janela de entrega. Note-se que o sequenciamento das entregas poderá ser realizado após o fecho do horizonte de agendamento (e com mais tempo!). Se o problema exigir sequenciamento de entregas (não apenas da estimativa do custo), pode ser interessante utilizar *Reinforcement Learning* modelando o VRP como um processo de decisão de *Markov*. Políticas de roteamento eficientes podem ser treinadas através da repetição de episódios, observando recompensas e respeitando restrições. Recentemente, vários autores propuseram abordagens deste género obtendo soluções de boa qualidade para problemas de transportes [5].

#### DESAFIOS FUTUROS

Para além da necessidade de desenvolver novas técnicas que combinem ML com Otimização, e da quantidade de dados que estas téc-

nicas exigem, a utilização de ML ainda está a dar os primeiros passos para a integração na sociedade. O facto de a maior parte destas técnicas serem vistas como caixas negras acaba por dificultar a sua adoção devido à falta de confiança dos utilizadores nos outputs dos sistemas baseados em ML. Nesse sentido, a comunidade científica tem feito um esforço tremendo para aumentar a explicabilidade dos modelos e, ao mesmo tempo, garantir que o próprio sistema de ML está ciente do ambiente em que está inserido.

Por último, não nos podemos esquecer que estes sistemas estarão a tomar decisões com impactos diversos no bem-estar das pessoas, por exemplo no acesso a crédito bancário, na saúde de pacientes, ou mesmo na segurança de passageiros de um veículo autónomo. Isto levanta várias questões éticas, legais e económicas, que têm sido levantadas por várias entidades. A União Europeia por exemplo definiu sete princípios para uma inteligência artificial confiável, que incluem controlo humano, robustez e segurança, privacidade, transparência, equidade, bem-estar e responsabilização.

#### REFERÊNCIAS

- [1] Bertsimas, D., King, A., & Mazumder, R. (2016). *Best subset selection via a modern optimization lens*. *The Annals of Statistics*, 44(2):813–852.
- [2] Karimi-Mamaghan, M., Mohammadi, M., Meyer, P., Karimi-Mamaghan, A.M., & Talbi, E.-G. (2022). *Machine learning at the service of metaheuristics for solving combinatorial optimization problems: A state-of-the-art*. *European Journal of Operational Research*, 296(2):393-422.
- [3] Koza, J.R. (1994). *Genetic programming as a means for programming computers by natural selection*. *Statistics and Computing*, 4(2):87-112.
- [4] Miller, A. (2002). *Subset selection in regression*. CRC Press.
- [5] Nazari, M., Oroojlooy, A., Takáč, M., & Snyder, L.V. (2018). *Reinforcement learning for solving the vehicle routing problem*. *NIPS'18*, page 9861–9871, Red Hook, NY, USA. Curran Associates Inc.
- [6] Powell, W. (2019). *Reinforcement learning and stochastic optimization*. Wiley, Hoboken, New Jersey.
- [7] Shahzad, A. & Mebarki, N. (2012). *Data mining based job dispatching using hybrid simulation-optimization approach for shop scheduling problem*. *Engineering Applications of Artificial Intelligence*, 25(6):1173–1181.
- [8] Snoek, J., Larochelle, H., & Adams, R.P. (2012). *Practical bayesian optimization of machine learning algorithms*. *Advances in Neural Information Processing Systems*, 25.
- [9] Sun, S., Cao, Z., Zhu, H., & Zhao, J. (2020). *A survey of optimization methods from a machine learning perspective*. *IEEE Transactions on Cybernetics*, 50(8):3668–3681.
- [10] Sutton, R.S. and Barto, A.G. (2018). *Reinforcement learning: An introduction*. MIT press.

# OTIMIZAÇÃO DE ROTAS PERIÓDICAS NUM SERVIÇO DE APOIO DOMICILIÁRIO



FILIFE ALVES

Research Centre in Digitalization  
and Intelligent Robotics (CeDRI)  
Instituto Politécnico de Bragança,  
Programa Doutorral  
em Engenharia Industrial e de Sistemas,  
Universidade do Minho  
[filipealves@ipb.pt](mailto:filipealves@ipb.pt)



FILIFE ALVELOS

Centro Algoritmi/Departamento  
de Produção e Sistemas,  
Universidade do Minho  
[falvelos@dps.uminho.pt](mailto:falvelos@dps.uminho.pt)



ANA MARIA A. C. ROCHA

Centro Algoritmi/Departamento  
de Produção e Sistemas,  
Universidade do Minho  
[arocha@dps.uminho.pt](mailto:arocha@dps.uminho.pt)

Um serviço de apoio domiciliário (SAD) permite a prestação de cuidados (médicos, de enfermagem ou sociais) no domicílio dos seus utentes. Os SAD têm ganho importância em anos recentes, em particular em Portugal, por permitirem aos utentes menos deslocações e maior conforto no seu tratamento (de particular importância dado o envelhecimento da população). Por outro lado, permitem, ao sistema de saúde como um todo, a redução de custos, a maior adesão aos tratamentos por parte dos utentes e a redução dos contactos infecciosos (e.g. COVID em centros de saúde e infeções hospitalares em meio hospitalar).

A gestão de um SAD tem uma forte componente relativa à adequada utilização de recursos (médicos, enfermeiros, assistentes sociais, veículos) no cumprimento dos tratamentos dos utentes (tipicamente caracterizados em termos espaciais e temporais e ainda pelos requisitos específicos dos cuidadores).

Diversas abordagens baseadas em Investigação Operacional (IO) e áreas relacionadas têm sido aplicadas na gestão e planeamento operacional de SAD. Uma revisão focada em problemas de escalonamento e encaminhamento é feita em [4].

Neste texto descreve-se uma abordagem de IO ao planeamento das visitas de enfermeiros aos utentes do SAD da Unidade de Saúde de Santa Maria do Centro de Saúde de Bragança.

Na altura em que este estudo se iniciou este SAD tinha 15 utentes e enfermeiros disponíveis em número suficiente para fazer todas as visitas. No início de cada dia, de acordo com a perceção de quais os utentes que seria necessário visitar e a sua localização (i.e. dos seus domicílios), a enfermeira-chefe decidia quais os utentes que seriam visitados e por quais enfermeiros, não estipulando nenhuma sequência para as visitas e sem recurso a qualquer meio informático.

Em sintonia com o referido pela enfermeira-chefe definiu-se o problema base como sendo o de planear quais os utentes a serem visitados em cada dia e por que sequência, de forma à distância percorrida em toda a semana (cinco dias úteis) ser a menor possível.

Numa primeira fase, de estruturação do problema, discutiu-se a forma de caracterizar as visitas aos utentes, tendo-se definido que um utente era caracterizado pelo número de visitas semanais que tinha de receber e que estas teriam pelo

**“DESCREVE-SE UMA ABORDAGEM DE IO AO PLANEAMENTO DAS VISITAS DE ENFERMEIROS AOS UTENTES DO SAD [SERVIÇO DE APOIO DOMICILIÁRIO] DA UNIDADE DE SAÚDE DE SANTA MARIA DO CENTRO DE SAÚDE DE BRAGANÇA”**

menos um dia de intervalo.

Estando todos os enfermeiros habilitados a fazer qualquer tipo de tratamento, a decisão de qual o enfermeiro específico que iria fazer cada conjunto de visitas continuaria a ser tomada pela enfermeira-chefe. As sequências de visitas realizadas no mesmo dia por um mesmo enfermeiro, i.e., uma rota, teriam de ter início e final no centro de saúde e não poderiam ter duração superior a oito horas. Existia uma limitação ao número de rotas simultâneas por só existirem cinco veículos (com características semelhantes).

Resumindo, o problema em estudo consiste em determinar as rotas de cada dia útil da semana, cada uma respeitando uma duração máxima, de forma a garantir que os utentes recebem o correto número de visitas semanal, respeitando o espaçamento de um dia. Pretende-se que o comprimento total das rotas seja o menor possível.

Os problemas de rotas (“Vehicle Routing Problems” - VRP ou problemas de encaminhamento de veículos) [3, 5] são dos problemas mais estudados em IO e áreas relacionadas. O problema em estudo pode ser formulado como um problema de encaminhamento de rotas periódico (“Periodic VRP”) [2], ou, mais especificamente, como um problema do caixeiro-viajante múltiplo periódico (dado que, na terminologia dos VRP, os clientes não têm procura e os veículos não têm capacidade).

Excluíram-se abordagens de otimização com incerteza, depois de ponderado o impacto de se considerar a incerteza na qualidade da solução (que se avaliou como sendo baixo) e do maior

esforço que implicaria na recolha de dados, caracterização das variáveis aleatórias e desenvolvimento de métodos mais elaborados. Considerou-se apenas um objetivo que resultou da clara prioridade apontada pela agente de decisão. É bem conhecido que, de forma geral, os VRP são de difícil resolução (NP-difíceis), tendo-se colocado a questão de qual a abordagem a seguir de entre as duas grandes famílias de otimização: Programação Inteira Mista (PIM) ou (meta-)heurísticas.

A obtenção de uma solução ótima não era um aspeto decisivo, dada a fragilidade do conceito de otimalidade num modelo determinístico em que os parâmetros são estimados e inerentemente incertos. Na função objetivo, as distâncias euclidianas foram usadas como um *proxy* para as distâncias rodoviárias; nas restrições de duração máxima, os tempos de deslocação foram estimados através de distâncias euclidianas e assumindo uma velocidade constante e os tempos de tratamento foram estimados com base na experiência dos enfermeiros. Optou-se por uma abordagem baseada em PIM com base em:

1. A formalização num modelo matemático ser, por si só, uma contribuição para a estruturação e consequente resolução do problema em estudo.
2. Serem conhecidos vários modelos PIM para o problema base passíveis de serem estendidos para terem em conta novas características do problema (e.g., número máximo de clientes por rota, balanceamento da duração das rotas, janelas temporais, aspetos relacionados com custos, enfermeiros com diferentes especializações) atenuando a menor flexibilidade da PIM quando comparada com meta-heurísticas de forma geral.
3. Alguns desses modelos serem compactos o que permite a sua implementação direta, e.g. através de uma linguagem de modelação, conduzindo a um tempo de implementação menor do que as abordagens meta-heurísticas ou de modelos baseados em enumeração de rotas. O modelo é carregado para o *solver* de uma só vez e por ele resolvido sem mais intervenção do utilizador.
4. A PIM permitir ter uma medida da qualidade da solução, já que se baseia na obtenção de limites inferiores e superiores que definem intervalos de otimalidade (*optimality gap*) para o valor da solução ótima.

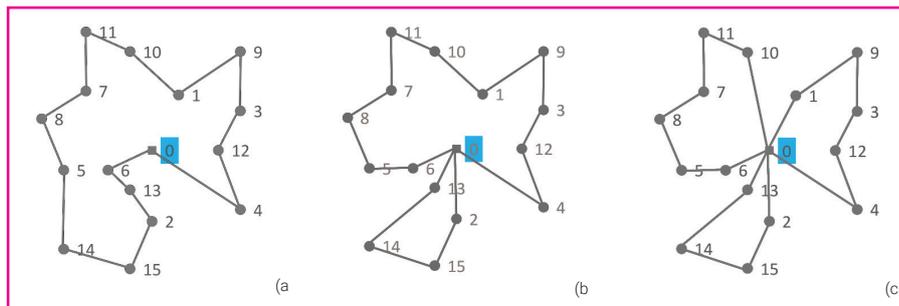


Fig. 1 - Soluções para problemas em que todas as visitas são feitas no mesmo dia. O centro de saúde está representado a azul.

5. Caso o modelo PIM se revelasse demasiado pesado poderia ser usado de forma heurística, por exemplo, definindo subproblemas em que algumas variáveis de decisão são fixadas. De acordo com a preocupação da enfermeira-chefe, o estudo focou-se na instância com que se debatia o centro de saúde na altura da realização do estudo. Diferentes variantes do modelo foram implementadas em OPL no IDE IBM Ilog Cplex Optimization Studio 12.7 com ligações ao Excel para leitura de dados e escrita da solução. As corridas foram efetuadas num computador com um processador Intel Core i7 CPU 2.2GHz com 6.0 GB de RAM.

O modelo PIM implementado baseia-se na enumeração dos padrões semanais de visita a cada utente. Por exemplo, um utente que necessite de duas visitas, ficará associado a um dos padrões 1-3, 1-4, 1-5, 2-4, 2-5 ou 3-5 em que os números são os índices dos dias da semana. Assim, há uma variável de decisão binária associada a cada par padrão/utente e restrições que forçam à seleção de um padrão adequado para cada utente.

O outro conjunto principal de variáveis de decisão define as rotas para cada dia e é formado por variáveis de decisão binárias que tomam valor um se o local (centro de saúde ou utente) é visitado imediatamente após outro num determinado dia por um determinado veículo e tomam valor zero caso contrário. Restrições de conservação de fluxo relacionando estas variáveis garantem que as sequências formam circuitos.

Para a eliminação de subcircuitos usaram-se as variáveis de decisão de sequência e as restrições de Miller-Tucker-Zemlin (em número polinomial). Restrições de ligação, entre as variáveis de padrões com as variáveis de rotas, forçam a

que um utente faça parte de uma rota nos dias definidos pelo padrão para ele selecionado. O modelo agora descrito está detalhado em [1].

O modelo tem simetria e o número de potenciais rotas/veículos é claramente superior ao necessário. No entanto, constatou-se que a inclusão de restrições para quebrar a simetria ou a redução da dimensão do problema não melhoraram o tempo computacional, comprovando-se a eficácia do pré-processamento do *solver*.

Para validação e maior *insight*, começou-se por resolver problemas relacionados com o problema em estudo. Consideraram-se três tipos de tratamento demorando 10, 20 e 30 minutos, distâncias euclidianas e uma velocidade dos veículos de 50 km/h.

Na Fig. 1 representam-se as soluções ótimas para o problema em que todos os utentes teriam de ser visitados no mesmo dia numa única rota sem limite de duração (Fig. 1 (a) - problema do caixeiro-viajante) e em, no máximo, cinco rotas (problema do caixeiro-viajante múltiplo) com li-

**“O PROBLEMA EM ESTUDO CONSISTE EM DETERMINAR AS ROTAS DE CADA DIA ÚTIL DA SEMANA (...) DE FORMA A GARANTIR QUE OS UTENTES RECEBEM O CORRETO NÚMERO DE VISITAS SEMANAL, RESPEITANDO O ESPAÇAMENTO DE UM DIA”**

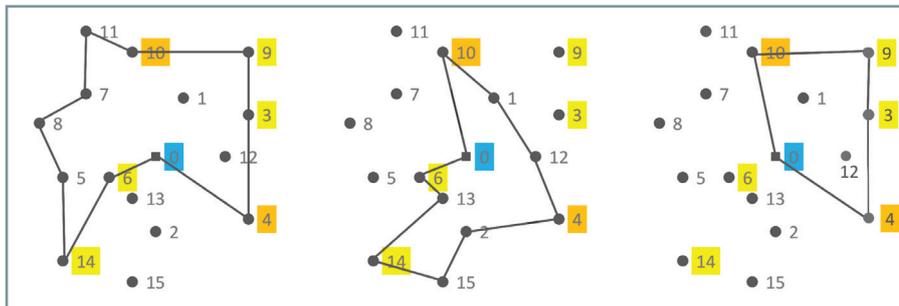


Fig. 2 - Rotas de segunda-feira, quarta-feira e sexta-feira para o problema sem limite de duração por rota. Utentes representados a amarelo têm duas visitas por semana e os representados a laranja têm três visitas por semana. Os restantes são visitados apenas uma vez por semana.

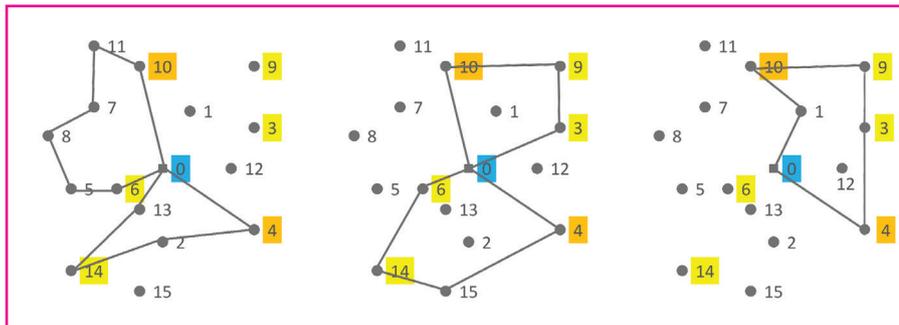


Fig. 3 - Rotas de segunda-feira, quarta-feira e sexta-feira para o problema com limite de quatro horas por rota.

mites de duração por rota de 8 horas (Fig. 1(b)) e de 4 horas (Fig. 1(c)). O valor das soluções ótimas foram de 229 km, 253 km e 278 km, e foram obtidas em cerca de um segundo, um minuto e três minutos, respetivamente.

Considerou-se de seguida o problema periódico sem limite de duração por rota, tendo-se obtido a solução ótima da Fig. 2 em que há três rotas à segunda, quarta e sexta. O modelo PIM tem cerca de sete mil variáveis de decisão e cerca de seis mil restrições. O valor da solução ótima é de 473 km e foi obtida em 11 horas. Nenhuma das rotas tem mais de oito horas, pelo que a solução é também ótima do problema com essa limitação.

Embora o *solver* tenha demorado onze horas, é de salientar que a solução ótima foi obtida ao fim de cerca de 10 minutos, tendo o resto do tempo sido despendido a melhorar o limite inferior. Uma solução com mais 2 km do que a ótima foi obtida em menos de dois minutos. Observou-se o mesmo comportamento, i.e., uma solução de qualidade ser obtida muito rapidamente, na resolução de várias versões do problema.

Assim, para outras instâncias do mesmo problema poder-se-á usar o modelo PIM com o tempo de execução (e.g. duas horas) como critério de paragem, não sendo prejudicada de forma significativa a qualidade da solução.

A solução aqui apresentada foi implementada,

traduzindo-se, de acordo com o estimado pela enfermeira-chefe numa redução semanal de 5% nos custos relativos às deslocações dos enfermeiros.

Uma proposta efetuada foi a consideração de períodos de manhã e de tarde através da limitação da duração das rotas a quatro horas. Dessa forma, embora aumentando a distância, seria possível um maior balanceamento entre enfermeiros, como representado na Fig. 3 em que a solução tem 514 km e foi obtida em menos de duas horas.

A continuação natural deste projeto seria a informatização do processo de definição de rotas semanais, o que envolveria a criação de uma interface que permitisse ao utilizador a alteração dos dados do problema (e.g. número e características dos utentes), bem como a visualização das rotas obtidas pela otimização. A precisão dos parâmetros (distâncias, tempos de deslocação e de tratamentos) do modelo poderia também ser melhorada. A relevância da inclusão de outros aspetos do problema, alguns dos quais já referidos, seria também uma discussão a ter com a agente de decisão.

Neste trabalho aplicou-se programação inteira mista ao problema da definição de visitas domiciliárias. Foi possível obter soluções de qualidade (ótima no caso do problema principal) utilizando como critério de paragem um tempo limite. Contribuiu-se ainda para a estruturação do planeamento do SAD, que passou de diário a semanal, e para uma redução efetiva dos custos operacionais associados às visitas.

O trabalho aqui descrito foi realizado no âmbito da Unidade Curricular de "Otimização de Redes" do Programa Doutoral em Engenharia Industrial e de Sistemas da Universidade do Minho. Os autores agradecem à Senhora Enfermeira Anabela Martins da Unidade de Saúde de Santa Maria do Centro de Saúde de Bragança. Filipe Alves agradece à FCT - Fundação para a Ciência e a Tecnologia o apoio à investigação com a bolsa de doutoramento SFRH/BD/143745/2019.

## REFERÊNCIAS

- [1] Alves, F., Alvelos, F., Rocha, A.M.A.C., Pereira, A.I., & Leitão, P. (2019). Periodic vehicle routing problem in a health unit. *Proceedings of the 8th International Conference on Operations Research and Enterprise Systems*, 384–389. <https://doi.org/10.5220/0007392803840389>
- [2] Campbell, A.M. & Wilson, J.H. (2014). Forty years of periodic vehicle routing. *Networks*, 63(1):2–15.
- [3] Dantzig, G.B., & Ramser, J.H. (1959). "The Truck Dispatching Problem". *Management Science*, 6 (1).
- [4] Fikar, C. & Hirsch, P. (2017). Home health care routing and scheduling: A review. *Computers & Operations Research*, 77:86–95.
- [5] Laporte, G. (2009). Fifty years of vehicle routing. *Transportation science*, 43(4), 408-416.

# PROBLEMAS DE ROTEAMENTO E ARMAZENAMENTO EM TRANSPORTE MARÍTIMO

O transporte marítimo é, hoje em dia, a principal forma de movimentar mercadorias entre locais distantes, o que faz com que seja muito estudado por vários investigadores espalhados pelo mundo. Existem vários problemas de otimização associados ao transporte marítimo tais como a definição das rotas dos navios, a gestão de stocks nos portos, o planeamento da atracação dos navios nos portos, o escalonamento das operações de carga/descarga nos portos, etc. O estudo integrado de vários problemas de otimização permite a obtenção de melhores soluções globais. No entanto, a elevada complexidade de cada um destes problemas faz com que muitas vezes essa integração não seja possível. Além disso, os problemas de otimização associados ao transporte marítimo estão altamente sujeitos a várias fontes de incerteza e o problema de Roteamento e Armazenamento em Transporte Marítimo (RATM) não é exceção. Neste problema, onde o decisor é responsável não só por definir as rotas de cada navio como também por gerir os stocks dos produtos nos portos (evitando ruturas), a incerteza surge frequentemente nos tempos de viagem dos navios. Condições meteorológicas e falhas mecânicas nos navios são algumas das principais fontes dessa incerteza. Assim sendo, estudar este problema sob incerteza é crucial para garantir a obtenção de boas soluções.

No problema de RATM consideram-se vários

portos, sendo alguns deles consumidores e outros produtores e assumem-se as taxas de consumo e produção, respetivamente, como constantes. Em cada porto existem limites máximos e mínimos para o stock de determinados produtos e por isso é necessário que os navios visitem constantemente esses portos para carregar/descarregar produtos por forma a manter os níveis de stock dentro dos limites estabelecidos. A Fig. 1 representa os níveis de stock ao longo do tempo em portos de produção e de consumo, respetivamente. Os pontos a vermelho representam instantes de chegada de navios aos portos e as linhas verdes representam o nível de stock no porto durante as operações de carga/descarga dos navios.

## MODELAÇÃO

A modelação de um problema de RATM determinístico, em que se assume o tempo como contínuo, envolve um grande número de variáveis e restrições. É necessário definir a rota detalhada de cada navio (isto é, a sequência de portos por ele visitados), os instantes de partida e chegada a cada porto e as quantidades carregadas/descarregadas em cada porto. Além disso, é necessário ainda um conjunto de variáveis que permita controlar os níveis de stock em cada porto. A incorporação da incerteza num problema de RATM (tal como na maior parte dos problemas de otimização) conduz à necessidade de identificar a altura



FILIPE RODRIGUES

Departamento de Matemática,  
Instituto Superior de Economia e Gestão,  
Universidade de Lisboa  
frodriques@iseg.ulisboa.pt

**“EXISTEM VÁRIOS PROBLEMAS DE OTIMIZAÇÃO ASSOCIADOS AO TRANSPORTE MARÍTIMO TAIS COMO A DEFINIÇÃO DAS ROTAS DOS NAVIOS, A GESTÃO DE STOCKS NOS PORTOS, O PLANEAMENTO DA ATRACAÇÃO DOS NAVIOS NOS PORTOS, O ESCALONAMENTO DAS OPERAÇÕES DE CARGA/DESCARGA NOS PORTOS, ETC”**

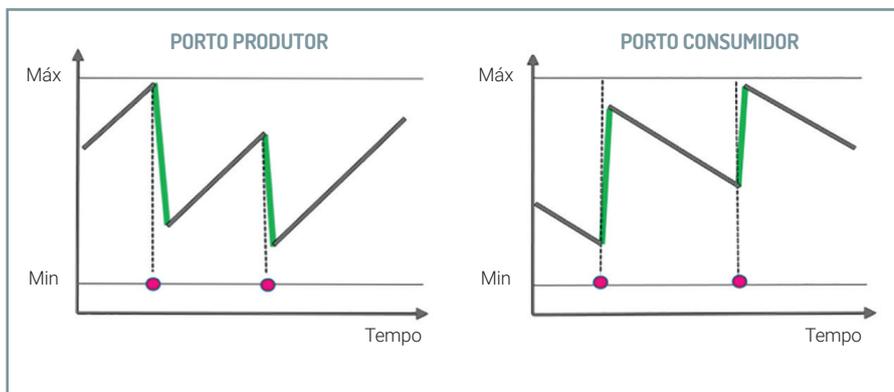


Fig. 1 - Variação do nível de stock em portos produtores e consumidores.

em que as decisões são tomadas. No caso do problema de RATM, existem decisões que dificilmente podem ser alteradas, como é o caso das rotas dos navios e das quantidades a carregar/descarregar em cada porto – estas são decisões de primeiro estado definidas antes da incerteza ser conhecida, isto é, aquando da fase de planeamento. Outras decisões, como é o caso dos tempos de chegada dos navios aos portos e os níveis de stock em cada porto aquando dessas chegadas, são altamente dependentes da incerteza nos tempos de viagem dos navios – estas são decisões de segundo estado, tomadas/definidas apenas quando a incerteza é revelada, isto é, quando o planeamento efetuado é executado. Assim, ao introduzir incerteza no problema de RATM, faz sentido formulá-lo através de um modelo com dois estados de decisão.

#### ABORDAGENS PARA LIDAR COM INCERTEZA

Existem várias abordagens para modelar a incerteza, sendo a programação estocástica [1] e a otimização robusta [2] as mais comuns. O que distingue (e caracteriza) estas abordagens é o conhecimento que se possui acerca da incerteza e o tipo de objetivo que se pretende otimizar. A programação estocástica foca-se em otimizar o valor esperado de funções dependentes de parâmetros incertos/aleatórios cuja distribuição é conhecida. Por outro lado, a otimização robusta baseia-se em otimizar funções tendo em conta os valores de incerteza que lhe são menos favoráveis – otimização do pior caso. Além disso, a otimização robusta assume que não existe uma distribuição subjacente à incerteza ou que tal distribuição não é conhecida.

Mas será que existem diferenças acentuadas entre as soluções das duas abordagens? E se existem, o que é que as caracteriza? Qual é a abordagem mais adequada para o problema de RATM? Estas são algumas das questões a que se tentou dar resposta [3]. Foram consideradas ainda outras abordagens para lidar com incerteza: uma abordagem puramen-

te determinística sem stocks de segurança, uma abordagem determinística com stocks de segurança nos portos para precaver ruturas de stock, uma abordagem estocástica baseada numa medida de risco: o condicional value-at-risk (CVAR) e, finalmente, uma abordagem híbrida que consistia em usar a abordagem anterior para definir stocks de segurança para o modelo determinístico com stocks de segurança.

#### PROCEDIMENTO

Para responder às questões referidas anteriormente, considerou-se um conjunto de instâncias reais referentes ao transporte marítimo de curta distância com longos tempos de operações de carga/descarga. Começou-se por resolver o modelo determinístico simples e o modelo determinístico com stocks de segurança através do Xpress obtendo assim uma solução para cada uma destas abordagens para cada uma das instâncias de teste. Através de um algoritmo de decomposição, obtiveram-se as soluções dos restantes quatro modelos (robusto, estocástico, CVAR e híbrido) para cada uma das instâncias e usou-se simulação para testar e comparar essas soluções. Para tal, foi gerado um grande conjunto de cenários de incerteza representando possíveis tempos de viagem de navios e calculadas algumas medidas de performance para cada uma das soluções obtidas, nomeadamente: o número de cenários em que a solução obtida levou a ruturas de stock, a ruturas mínima, média e máxima que a solução originou e o custo total de roteamento dos navios.

#### RESULTADOS

Esta investigação conduziu a várias conclusões interessantes e permitiu dar resposta a muitas das questões que a motivaram. Em primeiro lugar, verificou-se que as soluções obtidas pelas diferentes abordagens eram estruturalmente diferentes, nomeadamente no que respeita às rotas dos navios, ao núme-

ro de visitas a cada porto durante o horizonte temporal em estudo e ainda em relação às quantidades carregadas/descarregadas em cada porto. Infelizmente, não foi possível encontrar uma abordagem que dominasse todas as outras em relação a todas as medidas de performance consideradas, mas ficou claro que usar uma abordagem determinística num problema altamente sujeito a incerteza não é de todo uma boa opção. De facto, as soluções do modelo determinístico simples apresentam os piores valores em relação a todas as medidas de performance relacionadas com ruturas de stocks.

As soluções obtidas através do modelo robusto foram, em média, as melhores em termos do valor máximo de rutura de stocks no conjunto de cenários considerado. Para tal, contribuiu o facto de nestas soluções as visitas dos navios aos portos serem mais recorrentes, sendo por isso mais elevado o custo total de roteamento dos navios. Por outro lado, as soluções obtidas pelo modelo estocástico apresentaram baixos custos de roteamento, o que faz com que também apresentem valores elevados de rutura de stocks. Em termos de rutura média e da probabilidade de ruturas, a abordagem híbrida revelou ser a que conduz a valores mais baixos. Assim sendo, as medidas de risco, como o CVAR, poderão ser usadas no futuro como forma de definir parâmetros para outros modelos tais como stocks de segurança ou até mesmo janelas temporais.

Em suma, poder-se-á então concluir que não existe uma abordagem que seja absolutamente melhor que todas as outras. Apenas se poderá afirmar que uma determinada abordagem é absolutamente melhor que outras em relação a determinadas medidas de performance. Assim sendo, a escolha de uma abordagem para lidar com a incerteza deverá ser cuidadosamente pensada, sendo que esta dependerá sempre das preferências do decisor e dos objetivos/políticas de cada porto.

#### REFERÊNCIAS

- [1] Agra, A., Christiansen, M., Hvattum, L.M., & Rodrigues, F. (2016). A MIP based local search heuristic for a stochastic maritime inventory routing problem. In: Paiais A., Ruthmair M., & Voß S. (eds) *Computational Logistics. ICCL 2016. Lecture Notes in Computer Science*, vol 9855. Springer, Cham. [https://doi.org/10.1007/978-3-319-44896-1\\_2](https://doi.org/10.1007/978-3-319-44896-1_2)
- [2] Agra, A., Christiansen, M., Hvattum, L.M., & Rodrigues, F. (2018). Robust optimization for a maritime inventory routing problem. *Transportation Science*, 52(3), 509-525.
- [3] Rodrigues, F., Agra, A., Christiansen, M., Hvattum, L.M., & Requejo, C. (2019). Comparing techniques for modelling uncertainty in a maritime inventory routing problem. *European Journal of Operational Research*, 277(3), 831-845.

# O SÓCIO N.º ... 1216

Quando temos um problema, temos que arranjar uma solução. É este o mote que de certa forma descreve o meu gosto pela Investigação Operacional (IO). A capacidade de resolver problemas usando o conhecimento, a experiência, e até a criatividade, motivaram-me quando ainda era aluno da Licenciatura de Engenharia Informática na Universidade do Minho (UM). No meu terceiro ano, tinha uma disciplina de modelos determinísticos de IO, lecionada pelo Professor José Valério de Carvalho. Fui-me apercebendo que poderia aplicar os paradigmas da programação que eu já tinha aprendido durante a licenciatura na resolução de problemas concretos da indústria e serviços. O Professor Valério de Carvalho, sem o saber, motivou-me para que eu decidisse fazer o Mestrado em Engenharia de Sistemas da UM. Nesse mestrado tive excelentes professores, mas um deles destacou-se: o Professor Cláudio Alves era o docente de Sistemas de Apoio à Decisão e eu tinha um percurso académico semelhante ao dele. Além disso tornou-se de imediato uma referência para mim: era excelente a explicar qualquer conceito com rigor e clareza, e era um professor extremamente disponível e motivador. Decidi por isso tentar a minha sorte: concorri a uma bolsa de investigação no âmbito de um projeto de otimização do corte na indústria de estofos automóveis que envolvia o Professor Cláudio e o Professor Valério de Carvalho. Fui o candidato escolhido e comecei assim a desenvolver a minha dissertação de mestrado: o objetivo era implementar heurísticas construtivas e mais tarde algoritmos de pesquisa local para posicionamento de cortantes em peles de couro de forma a minimizar o desperdício deste material natural. O interessante é que existem experientes operários fabris que conseguem alto aproveitamento das peles, e por isso era necessário ser competitivo e criar métodos automáticos que permitissem um bom aproveitamento das peles de couro. A equipa deste projeto foi distinguida com o Prémio Isabel Themido /IO2013 para o melhor artigo científico publicado em revistas científicas de circulação internacional (*ex aequo*). Adicionalmente, recebi o Prémio APDIO/IO2013 pela melhor dissertação de mestrado na área de IO (*ex aequo*).

À medida que ia finalizando a dissertação de

mestrado, comecei a preparar uma candidatura a uma bolsa de doutoramento com os mesmos professores que me acompanharam nesse projeto. O dia em que é concedida a bolsa FCT para frequentar o Programa Doutoral em Engenharia Industrial e de Sistemas da UM é um dos dias mais importantes do meu percurso: poderia desenvolver os meus trabalhos de investigação com esses dois excelentes professores. Foram anos em que aprendi muito para atacar o problema que me acompanhou durante vários anos (e ainda acompanha...): operações logísticas integradas com especial foco no planeamento de rotas com restrições de carregamento e sequenciamento. São problemas de otimização combinatória NP-Difíceis para os quais continua a ser difícil obter soluções ótimas em instâncias de média dimensão. No meu trabalho de doutoramento desenvolvi meta-heurísticas e algoritmos de geração de colunas para este problema. Além da complexidade do problema, a implementação desses algoritmos é desafiante... Mas contei com suporte dos orientadores que sempre me ajudaram a ultrapassar esses desafios.

Durante e após o doutoramento tive a excelente oportunidade de lecionar no Departamento de Produção e Sistemas da UM. Esta oportunidade, além de enriquecedora, foi muito gratificante: mostrou-me a grande satisfação que tenho em ensinar e mostrar casos práticos de aplicação da IO.

Depois de finalizar o doutoramento, integrei como bolsheiro de investigação um projeto no âmbito do Programa MIT Portugal denominado IAMAT (*Introduction of Advanced Materials Technologies into New Product Development for the Mobility Industries*). Este projeto tinha como objetivo desenvolver métodos e ferramentas para a indústria aeronáutica e melhorar as suas cadeias de abastecimento, tornando-as mais sustentáveis. Foi muito enriquecedor não só aprender novas conceções da cadeia de abastecimento, mas também poder trabalhar em equipa com investigadores de diferentes áreas científicas e de outras universidades como a Universidade do Porto ou Instituto Superior Técnico.

Em setembro de 2019 integrei a Universidade de Coimbra como Professor Auxiliar no Departamento de Engenharia Mecânica da Faculda-



TELMO PINTO

telmo.pinto@uc.pt  
DEM-FCTUC, CEMPRE, ALGORITMI  
telmo.pinto@uc.pt

de de Ciência e Tecnologia. A equipa de Engenharia e Gestão Industrial é ainda pequena, mas dinâmica e conta já com vários projetos e um papel ativo na área de IO.

No presente, a minha investigação tem-se centrado em problemas integrados de otimização combinatória, com especial atenção ao setor da distribuição e em técnicas exatas e híbridas para a resolução desses problemas. Como orientador, tenho tentado motivar alguns alunos para o desenvolvimento de modelos, métodos e estratégias de IO para problemas complexos e reais. Muitas vezes, a dificuldade na obtenção de soluções para estes problemas pode desmotivar... Por isso tento lembrar aos alunos (e a mim próprio...) uma frase de *Antoine de Saint-Exupéry* no seu livro *Voo Nocturno*, “[...] na vida, não há soluções, há forças em marcha: é preciso criá-las, e as soluções seguem-se”.

## EVENTOS A REALIZAR

### EUREKATHON Challenging Data for Sustainable Cities

12 a 14 de novembro de 2021  
Virtual Event  
Mais informações em: <https://www.eurekathon.com/>



**EUREKATHON**  
Challenging Data for Sustainable Cities

Powered by

12-14 NOVEMBER | VIRTUAL EVENT

Informations and registrations: [eurekathon.com](http://eurekathon.com)

### EURO 2022 - 32nd European Conference on Operational Research

3 a 6 de julho de 2022  
Espoo, Finlândia  
Mais informações em: <https://euro2022espoo.com/>



### EURO General Support Fund - Call for submission of bids for projects in 2023 and 2024

Mais informações em:  
<http://www.euro-online.org/awards/gsf2022/registration.php>

### EURO Support for NATCOR Bursaries NATCOR - National Taught Course Centre in Operational Research

Heuristic Optimisation and Learning, University of Nottingham - Residential 25 - 29 April 2022  
Convex Optimizaton, University of Edinburgh - Residential 6th - 10th June 2022  
Mais informações em: <https://www.euro-online.org/web/pages/1568/natcor-bursaries> <http://www.natcor.ac.uk/courses/>

### IO2021 - XXI Congresso da Associação Portuguesa de Investigação Operacional

7 a 8 de novembro de 2021  
Hotel Eurostars da Figueira da Foz, Portugal  
Mais informações em: <http://apdio.pt/web/io2021/home>



### Teses de Doutoramento

Autor: Ali Moghanni  
Título: Finding dissimilar paths: formulations and variants  
Instituição: Universidade de Coimbra  
Programa Inter-Universitário de Doutoramento em Matemática  
Data da conclusão: maio de 2021  
Orientadora: Marta Pascoal



Associação Portuguesa de Investigação Operacional  
Departamento de Engenharia e Gestão  
Instituto Superior Técnico  
Av. Rovisco Pais, 1  
1049-001 Lisboa, Portugal  
[apdio@civil.ist.utl.pt](mailto:apdio@civil.ist.utl.pt)



<http://apdio.pt/home>  
<https://www.facebook.com/APDIO.PT/>  
<https://www.linkedin.com/groups/2871069/>

BOLETIM  
APDIO

**Equipa Editorial**  
Eliana Costa e Silva  
[eos@estg.ipp.pt](mailto:eos@estg.ipp.pt)  
Rui Borges Lopes  
[rui.borges@ua.pt](mailto:rui.borges@ua.pt)

**Design**  
Inês Assis  
[inesassis.design@gmail.com](mailto:inesassis.design@gmail.com)  
**Impressão**  
Gráfica Pacense, Lda.  
**Tiragem** 325 exemplares