

## Optimisation of vehicle fleet capacity as determined through a simulation using the Monte Carlo algorithm

### Optimalizace vozového parku založená na algoritmu Monte Carlo

Ing. Martin Lampa, Ph.D.; Ing. Andrea Samolejová, Ph.D.

VŠB – Technical University of Ostrava, Faculty of Metallurgy and Materials Engineering, 17. listopadu 15/2172, 708 33 Ostrava-Poruba, Czech Republic

*S rozvojem výpočetní techniky a softwarových produktů dochází ke stále většímu uplatnění aritmetických (numerických) metod v manažerském rozhodování i v průmyslových podnicích. Rozhodování je jednou z nejvýznamnějších manažerských aktivit, které manažeři každodenně využívají při výkonu své funkce. Význam pojmu manažerské rozhodování se nejvíce projevuje v tom, že kvalita a výsledky rozhodovacích procesů ovlivňují efektivnost, fungování a prosperitu průmyslových podniků. Informace hrají v rozhodovacích procesech klíčovou úlohu. Rozhodovací procesy se obvykle chápou jako procesy shromažďování a transformace vstupních dat do výstupních informací. Zásadní úlohu v procesech získávání dat, shromažďování dat a jejich přeměny v informace hraje manažer, jehož znalosti, zkušenosti a intuice jsou nebytné pro správné rozhodování. Obvykle časový tlak a omezenost jednotlivých zdrojů zabraňují pečlivému hledání všech dat, na jejichž základě manažer získá kvalitní informace pro rozhodování. Nekvalitní informace a tím i nekvalitní rozhodování mohou být jeden z důvodů podnikatelského neúspěchu. Jeden z velmi dobře uplatnitelných simulačních algoritmů řešení na počítači je metoda Monte Carlo. Aplikace algoritmu Monte Carlo spočívá v nalezení souvislosti mezi jednotlivými veličinami, které jsou řešením zkoumaného problému a charakteristikami náhodných procesů reprodukovatelných na počítačích. Cílem článku je ukázat použití simulačního algoritmu Monte Carlo na příkladu optimalizace vozového parku tak, aby celkové denní náklady na přepravu zboží vozidly byly minimální.*

**Klíčová slova:** vědecké řízení; optimalizace; simulace; algoritmus Monte Carlo

*With the development of computers and software products, there is now greater use of quantitative methods in industrial enterprises when making managerial decisions. One of the most applicable solutions to computer simulation algorithms is the Monte Carlo method. The application of the Monte Carlo algorithm lies in finding a relation between the individual variables, which are the solutions to the problem and represent the characteristics of random processes reproducible on computers. The aim of this article is to show the application of simulations from the Monte Carlo algorithm using the example of optimising vehicle fleet capacity so that the total daily costs spent on transporting goods are minimal.*

**Key words:** management science; optimisation; simulation; Monte Carlo algorithm

Over the last two decades, there have been great advances in computer technology and these advances have also affected managerial decision-making [1]. Mathematical methods with the use of computer technologies have been increasingly used in most problems of managerial decision-making [6]. One of the most applicable methods of computer implementation is the Monte Carlo method [3]. A static, stochastic method uses random (pseudo-random) numbers in the course of the calculation [2]. In this article, its use will be shown while optimising vehicle fleet capacity so that the daily costs spent on transporting goods are minimal.

#### 1. The task

A company provides the transportation of goods based on customer orders according to the following rule:

Tab. 1 Day of ordering and the subsequent transport of the goods  
Tab. 1 Den objednání a následné přepravy zboží

Ordered on	Transported on
Monday	Tuesday
Tuesday	Wednesday
Wednesday	Thursday
Thursday	Friday
Friday	Monday

Orders are not received on Saturdays or Sundays and there is no transportation on these days. Transportation is carried out by using trucks. The daily cost of operating one truck is 600 € – provided the trucks operate 8 hours each day.

If an order requires overtime operation, i.e. an operation that exceeds the set 8-hour operational time, the costs for each overtime hour are 250 €.

Through statistical investigation for the assumption of a normal distribution of probability, the following data were determined:

- Data on the transport capacity of cars – on average, during an 8-hour running time, 1 car transports 80 orders with a standard deviation of 15 orders,
- Data on customer demand.

Tab. 2 Individual customer demands per respective days

Tab. 2 Nároky jednotlivých zákazníků na dané dny

Days	The average number of orders $x$	Standard deviation $\sigma$
Monday	7 800	800
Tuesday	6 400	700
Wednesday	5 500	600
Thursday	7 000	750
Friday	5 000	500

The business unit has to set an optimal vehicle fleet capacity so that the total daily costs spent on transportation are minimal.

## 2. Analysis of the solution

From the substantive point of view, this is a task that belongs to the methodology of the queuing theory [4]. It is a simple task to determine the optimal dimension (size, capacity) of the operating system:

- Operating system = vehicle fleet that provides transportation services,
- Two main variables are assumed (variables crucial to solution of the task)
  - operation intensity = transport capacity of the vehicle,
  - the intensity of the requirements entering the operating system = the number of orders.
- Number of the contracts has the character of random variables with a normal distribution of probability.

Two extreme situations (two extreme variations in the capacity of the operating system) that lead to relatively high costs of the activity may occur in terms of optimisation:

- A heavily oversized operating system (too many vehicles):
  - high costs of the vehicle fleet,
  - costs of overtime work converge to zero; the requests do not queue.
- A heavily undersized operating system (the number of vehicles is too small):
  - low costs of the vehicle fleet,
  - high costs for overtime work; formation of request queues (possible loss of profit due to queues).

Between the extreme variants, there is a number of possible variants of dimensioning the vehicle fleet that are associated with the different daily costs of transportation [5]. Of the possible variants, it is necessary to choose the optimal variant - the one with the lowest daily costs for transportation.

The following applies for the  $i$ -th variation of the operating system dimension:

$$N = N_V + N_M$$

$N$  – daily costs for transportation

$N_V$  – daily costs for operating the vehicle fleet

$N_M$  – daily overtime cost

## 3. The procedure of solving the task using a simulation of the Monte Carlo algorithm

For the assumption of normal probability distribution of both of the main variables:

1. The simulations (predictions) of the number of orders are performed according to the intensity of the requirements entering the operation. The simulation itself is in Tab. 3.

Tab. 3 Simulation of the number of orders

Tab. 3 Simulace počtu zakázek

Day	Simulated value of the distribution function <sup>*)</sup>	Determinant variable $t$	Prediction <sup>**)</sup> of the number of contracts $x = \bar{x} + t \cdot \sigma$
Mon	0.88147	1.1	8 680
Tue	0.9970	2.7	8 290
Wed	0.11941	-1.1	4 840
Thu	0.78817	0.8	7 600
Fri	0.17061	-0.9	4 550

<sup>\*)</sup> from the table of random numbers, we assume five-digit values for the distribution function of the normal probability distribution.

<sup>\*\*)</sup> Prediction of the number of orders:

$$x = \bar{x} + t \cdot \sigma$$

For Monday:  $x = 7\,800 + 1.1 \times 800$   **$x = 8\,680$**

For Tuesday:  $x = 6\,400 + 2.7 \times 700$   **$x = 8\,290$**

For Wednesday:  $x = 5\,500 - 1.1 \times 600$   **$x = 4\,840$**

For Thursday:  $x = 7\,000 + 0.8 \times 750$   **$x = 7\,600$**

For Friday:  $x = 5\,000 - 0.9 \times 500$   **$x = 4\,550$**

$\bar{x}$  – the average number of orders

$\sigma$  – determinant deviation

2. A simulation of the operational intensity of the 8-hour transportation capacity for the chosen number of vehicles is carried out: 70, 80, ..., 110

$n$  – the number of vehicles

$\bar{x}$  – mean value of operational intensity

$\bar{x}'$  – the average transport capacity of the fleet

Determining the number of vehicles for the highest number of orders:

The highest number of orders = 7 800

Determinant deviation = 800

One vehicle transports an average of 80 orders per hour

The total number of vehicles for the highest number of orders =  $(7\ 800 + 800)/80 = 110$

Determination of the number of vehicles for the lowest number of orders:

The lowest number of orders = 5 000

Determinant deviation = 500

One vehicle transports 80 orders per hour

The total number of vehicles for the lowest number of orders =  $(5\ 000 + 500)/80 = 70$

In the following step (Tab. 4), a simulation of the operational intensity is performed.

Tab. 4 Simulation of operational intensity

Tab. 4 Simulace intenzity obsluhy

The Number of vehicles $n$	Day	The simulated value of the distribution function of normal distribution	Determinant variable $t$	$\bar{x}' = n \cdot \bar{x}$	$\sigma' = \sqrt{n} \cdot \sigma$	Prediction of 8-hour transport capacity $\bar{x}' = x + t \cdot \sigma'$
70	Mon	0.33166	-0.4	5 600	126	5 550
	Tue	0.87094	1.1	5 600	126	5 739
	Wed	0.11120	-1.2	5 600	126	5 449
	Thu	0.22254	-0.7	5 600	126	5 512
	Fri	0.96023	1.7	5 600	126	5 814
80	Mon	0.76869	0.7	6 400	134	6 494
	Tue	0.39300	-0.2	6 400	134	6 373
	Wed	0.02982	-1.8	6 400	134	6 159
	Thu	0.57991	0.2	6 400	134	6 427
	Fri	0.94479	1.6	6 400	134	6 614
90	Mon	0.96023	1.7	7 200	142	7 441
	Tue	0.88936	1.2	7 200	142	7 370
	Wed	0.88936	-0.5	7 200	142	7 129
	Thu	0.55013	0.1	7 200	142	7 214
	Fri	0.10920	-1.2	7 200	142	7 030
100	Mon	0.26299	-0.6	8 000	150	7 910
	Tue	0.77806	0.7	8 000	150	8 105
	Wed	0.12446	-1.1	8 000	150	7 835
	Thu	0.23510	-0.7	8 000	150	7 895
	Fri	0.68774	0.4	8 000	150	8 060
110	Mon	0.48454	0	8 800	157	8 800
	Tue	0.65269	0.4	8 800	157	8 863
	Wed	0.18167	-0.9	8 800	157	8 659
	Thu	0.84631	1.0	8 800	157	8 957
	Fri	0.74108	0.6	8 800	157	8 894

Calculation example for  $n = 70$

$$\bar{x}' = 70 \times 80 = 5\ 600$$

$$\sigma' = \sqrt{70} \cdot 15 = 126$$

- The expected overtime is simulated (from the simulation of the number of orders and the eight-hour capacity of the fleet) in Tab. 5.

Tab. 5 Simulation of expected overtime operation  
Tab. 5 Simulace očekávaného přesčasového provozu

n	Day	Simulation		Prediction of expected overtime operation			
		The number of orders	8-hour capacity of the vehicle fleet	The number of pending orders	The number of overtime hours	The total number of overtime hours	The average number of daily overtime hours
70	Mon	7 800	5 550	2 250	225	445	89
	Tue	6 400	5 739	661	66		
	Wed	5 500	5 449	51	5		
	Thu	7 000	5 512	1 488	149		
	Fri	5 000	5 814	0	0		
80	Mon	7 800	6 494	1 306	131	191	38.2
	Tue	6 400	6 373	27	3		
	Wed	5 500	6 159	0	0		
	Thu	7 000	6 427	573	57		
	Fri	5 000	6 614	0	0		
90	Mon	7 800	7 441	359	36	36	7.2
	Tue	6 400	7 370	0	0		
	Wed	5 500	7 129	0	0		
	Thu	7 000	7 214	0	0		
	Fri	5 000	7 030	0	0		
100	Mon	7 800	7 910	0	0	0	0
	Tue	6 400	8 105	0	0		
	Wed	5 500	7 835	0	0		
	Thu	7 000	7 895	0	0		
	Fri	5 000	8 060	0	0		
110	Mon	7 800	8 800	0	0	0	0
	Tue	6 400	8 863	0	0		
	Wed	5 500	8 659	0	0		
	Thu	7 000	8 957	0	0		
	Fri	5 000	8 893	0	0		

#### 4. The result of the task - recommended by the simulation calculations

A calculation of the total daily costs for transportation with the individual numbers of vehicles is shown below:

$$N = N_V + N_M$$

$$N_{70} = 70 \times 600 + 89 \times 250 = 64\,250 \text{ €}$$

$$N_{80} = 80 \times 600 + 38.2 \times 250 = \mathbf{57\,550 \text{ €}}$$

$$N_{90} = 90 \times 600 + 7.2 \times 250 = \mathbf{58\,500 \text{ €}}$$

$$N_{100} = 100 \times 600 + 0 \times 250 = 60\,000 \text{ €}$$

$$N_{110} = 110 \times 600 + 0 \times 250 = 66\,000 \text{ €}$$

Under the given conditions, the total daily transport costs will be minimised when operating 80 vehicles or 80 to 90 vehicles.

#### Conclusions

As seen from the article, in this case, the use of the Monte Carlo algorithm is very appropriate when dealing with the problem of optimal vehicle fleet capacity. It was found that the overall lowest daily transport costs are 57 500 € when using 80 trucks. In this case, MS Excel was used to generate pseudorandom numbers. Computers play an indispensable role at the application of simulations and not using them in today's field of quantitative methods of managerial decision-making is unimaginable.

#### Acknowledgements

*The work was supported by the specific university research of Ministry of Education, Youth and Sports of the Czech Republic No. SP2015/90.*

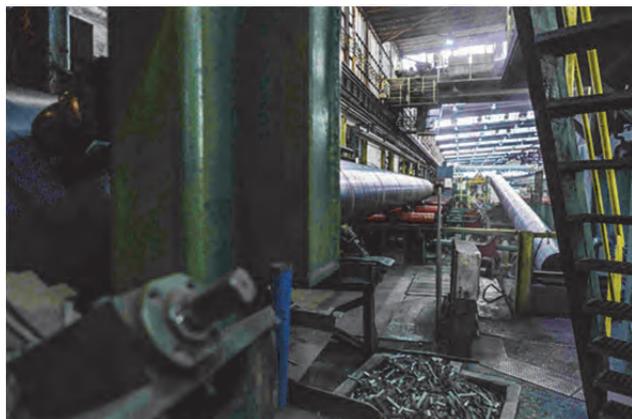
#### Literature

- [1] TVRDOŇ, L.; LENORT, R. Industrial Control System Make to Stock Decision Making in Metallurgical Companies. In *METAL 2011: 20th Anniversary International Conference on Metallurgy and Materials*, Ostrava: TANGER, 2011, pp. 1223–1228. ISBN 978-80-87294-24-6.
- [2] BESTA, P.; SAMOLEJOVÁ, A.; LENORT, R.; ZAPLETAL, F. Innovative Application of Mathematical Methods in Evaluation of Ore Raw Materials for Production of Iron. *METALURGIJA*, 53 (2014) 1, 93–96.
- [3] GROS, I.; DYNTAR, J. *Matematické modely pro manažerské rozhodování*. 2. uprav. a rozšíř. vyd. Praha: VŠCHT, 2015. 303 s.
- [4] JANOVSÁ, K.; VOZŇAKOVÁ, I.; ŠVAJDOVÁ, L. The Verification of Applicability of Economical-Mathematics Methods of Structural Analysis as a Tool for Optimising Economic Proceedings of Metallurgical Enterprise. In *METAL 2010: 19th Anniversary International Conference on Metallurgy and Materials*. Ostrava: TANGER, 2010, pp. 121–124. ISBN 978-80-87294-17-8.
- [5] WICHER, P.; STAŠ, D.; KARKULA, M.; LENORT, R.; BESTA, P. A Computer Simulation-Based Analysis of Supply Chains Resilience in Industrial Environment. *METALURGIJA*, 54 (2015) 4, 703–706.
- [6] SAMOLEJOVÁ, A.; FELIKS, J.; LENORT, R.; BESTA, P. Hybrid Decision Support System for Iron Ore Supply. *METALURGIJA*, 51 (2012) 1, 91–93.

## Ostravská válcovna trubek ArcelorMittal se podílí na stavbě 2 000 km plynovodu v Polsku

Společnost ArcelorMittal Tubular Products Ostrava (AMTPO), největší výrobce trubek v Česku, se bude podílet na výstavbě rozsáhlé sítě plynovodů v Polsku. Účelem nového plynového koridoru je dokončit plynifikaci Polska a propojit stávající LNG terminál se zbytkem Evropy. V březnu poputuje z AMTPO na stavbu plynovodu prvních pět kilometrů spirálově svařovaných trubek.

*„Stavba plynového koridoru v Polsku je dnes nejrozsáhlejším projektem tohoto typu v Evropě. Podílet se na této zakázce spolu s dalšími dodavateli je pro nás ohromnou příležitostí, která vzhledem k velikosti a předpokládané době trvání projektu nabízí možnost dlouhodobé spolupráce,“* říká Libor Černý, generální ředitel AMTPO.



Nové plynovody budou tvořit koridor sever-jih, který propojí polské plynovody s dalšími zeměmi napříč Evropou. Vytvoří se oboustranný koridor navazující na terminál LNG v Swinoujscie a další stávající infrastruktury v České republice, Rakousku, Maďarsku, Chorvatsku a na Slovensku.

- Z tiskové zprávy ArcelorMittal březen 2016 -

## Superkov by mohl dělat konkurenci hliníku

*Stahl Aktuell*

23.02.2016

Výzkumníci z univerzity v Los Angeles (UCLA) vyvinuli extrémně pevný a přesto velmi lehký materiál, který by mohl vytvořit konkurenci hliníku, doposud v lehkých konstrukcích preferovaného. Podle sdělení UCLA se „superkov“ vytvoří tým, že se do hořčíku v tekutém stavu přimíchají nanočástičky silikonkarbidu. Hořčík, který má o třetinu menší hustotu než hliník, je nejllehčí kov se strukturou. Silikonkarbid je ultratvrdá keramická látka, která je používána především pro průmyslové nože. Směs těchto dvou látek se postará o to, že hořčíkový nanokompozit je pevnější a má vyšší tuhost než doposud používané materiály pro lehké konstrukce. Kromě toho se dá lépe tvářet a je také žáruvzdornější. Šéf výzkumné skupiny v UCLA Xiaochun Li říká, že se výzkumníci zatím jen dotkli možných výsledků. „V novém systému se skrývá nová třída kovů s revolučními vlastnostmi“.