

Analýza dát za účelom zlepšenia konkrétneho procesu logistickej firmy

Miroslava Muchová, Ján Paralič

Fakulta elektrotechniky a informatiky
Technická univerzita v Košiciach
Letná 9/B, 042 00 Košice, Slovenská republika

{miroslava.muchova, jan.paralic}@tuke.sk

Abstrakt. Systém pre podporu rozhodovania v riadení logistiky môže poskytnúť manažérom logistických spoločností cenné informácie potrebné pre uskutočnenie efektívnych rozhodnutí. Jednou z kľúčových a často riešených úloh v logistickej firme nie je len otázka nízkej spotreby paliva ale aj rozhodnutie akého vodiča priradiť na akú trasu. Cieľom článku je aplikovať techniky prediktívneho dolovania dát a analyzovať štýl jazdy vodičov ako aj určiť kombináciu faktorov vplývajúcich na spotrebu paliva. Predkladaný článok sa okrem iného zaoberá aj problematikou analýzy dát pre zlepšenie rozhodovania vo vybranom logistickom procese – výber vodičov na plánované dodacie trasy. Vykonaný dotazníkový prieskum ukazuje, že v logistických a prepravných spoločnostiach chýba systém, ktorý by uľahčil priradenie vodičov na dodaciu trasu.

Kľúčové slová: analýza dát, priemerná spotreba paliva, systém pre podporu rozhodovania, Naive Bayes

1 Úvod

V poslednej dobe rôzne výskumné štúdie poukázali na výhody použitia veľkých dátových metód v oblasti logistiky a riadenia dodávateľského reťazca. Tan, K. H. a kolektív navrhli analýzu infraštruktúry veľkých dát na posilnenie schopnosti v oblasti inovácií dodávateľského reťazca [6]. Çakıcı prišiel s nápadom použiť RFID údaje na prepracovanie optimálnej politiky zásob [1]. Zhong prišiel s návrhom ako informácie z veľkých dát môžu byť použité na efektívne plánovanie logistiky a plánovanie výroby [8]. Dutta a Bose predstavili riadenie veľkých objemov dát pomocou logistických sietí [2]. Waller a Fawcett argumentujú, že používanie údajov, prediktívnej analýzy môže pomôcť manažérom logistiky splniť interné potreby a prispôsobiť sa zmenám v dodávateľskom reťazci. Jednoducho povedané, nasadenie analýzy dát pre logistiku a riadenie dodávateľského reťazca by malo zvýšiť pridanú hodnotu pre zákazníkov, pričom integrovaný výrobný a distribučný proces v celom dodávateľskom reťazci zahŕňa aj výrobcov, dodávateľov, maloobchodníkov, poskytovateľov logistických služieb, ktoré sú podporované použitím veľkého množstva informácií [7].

*J. Steinberger, M. Zíma, D. Fiala, M. Dostal, M. Nykl (eds.)
Data a znalosti 2017, Plzeň, 5. - 6. října 2017, pp. 221-226.*

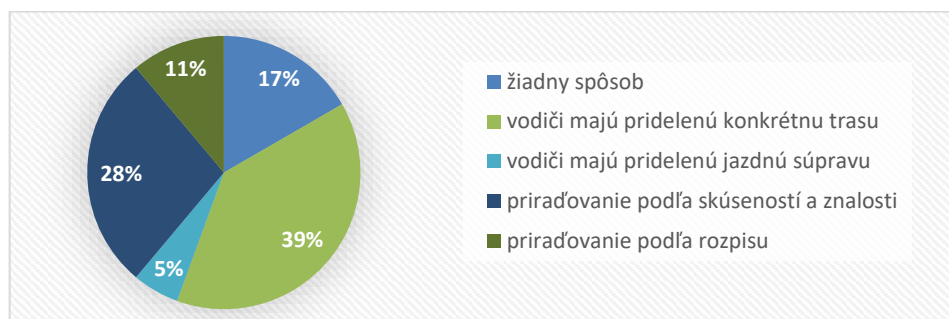
V tomto článku sa preto chceme zamerať na verifikáciu tvrdenia o prínose analýzy dát za účelom zlepšenia konkrétneho firemného procesu – výberu vodičov na plánované dodacie trasy v konkrétnej logistickej firme. Okrem iného, cieľom článku je aplikovať techniky prediktívneho dolovania dát, vďaka ktorým môžeme určiť hlavné faktory, ktoré ovplyvňujú priemernú spotrebu paliva ako aj identifikovať najvhodnejšie jazdné postupy a štýly vodičov.

2 Dotazníkový prieskum

Hlavným cieľom výskumu je vytvoriť systém pre podporu rozhodovania pre výber vodiča na konkrétnu trasu. Z toho dôvodu bol vykonaný prieskum medzi logistickými spoločnosťami. Vykonaný dotazníkový prieskum ukazuje, že v logistických a prepravných spoločnostiach chýba systém, ktorý by uľahčil pridelovanie vodičov na dodaciu trasu.

Prostredníctvom mailu bolo oslovených viac ako 300 logistických a prepravných spoločností. Jednou z otázok bolo aj, či by si vedeli predstaviť systém, ktorý rozhodne akého vodiča priradí na akú trasu, 10% opýtaných si takýto systém nevedia predstaviť, 40% by takýto systém nevyužili a 50% spoločností by takýto systém vedeli využiť a v súčasnosti jeden takýto systém testujú a plánujú ho nasadiť. Okrem toho sme prostredníctvom dotazníkov zistili, že viac ako 88% spoločností analyzuje nejakým spôsobom jazdný štýl vodiča, pričom asi 46% na analýzu využíva program.

Na nasledujúcom obrázku môžeme vidieť zloženie odpovedí na ďalšiu položenú otázku: Akým spôsobom priradzujete vodičov na konkrétnu trasu?



Obr. 1. Odpovede na otázku získané prostredníctvom dotazníkového prieskumu

3 Analýza zvolenej množiny dát

Dáta, ktoré máme k dispozícii pochádzajú z prepravnej spoločnosti. Jedná sa o firmu, ktorej predmetom činnosti podľa obchodného registra je výkon povolania prevádzkovateľa nákladnej cestnej dopravy. K dispozícii boli dáta o deviatich vozidlách (z toho sú už tri vyradené) a o pätnástich vodičoch.

Firma na komunikáciu s vozidlami využíva systém Dynafleet Online – Volvo Truck Corporation [5]. Informácie sťahované z vozidiel sú ukladané do databázy. Pre účely našej práce sme mali k dispozícii dva výkazy a to Výkaz hodnotenia spotreby paliva, ktorý obsahoval 26 atribútov, ako napr. meno vodiča, dátum, priemerná rýchlosť, priemerná spotreba paliva a ďalšie atribúty, ktoré podávajú informáciu o celkovom hodnotení jazdného štýlu vodiča – predvídanie, tempomat, voľný dojazd, úsporná a neúsporná jazda atď. Druhým výkazom bol Výkaz sledovania a obsahoval 24 atribútov, napr. čas udalosti, prejdená vzdialenosť, palivo, miesto, hmotnosť nákladu a podobne. Všetky dáta boli uložené vo formáte excelovských tabuliek.

3.1 Príprava dát

Pre potreby našich analýz, sme na základe dátumu obidva dátové súbory zlúčili a informácie o všetkých vozidlách sme spojili do jedného súboru. Získali sme tak 49 atribútov a vyše 2900 záznamov. Odstránili sme nepodstatné atribúty (napr. atribút Úplné zastavenie mal rovnaké hodnoty ako atribút Voľnobeh, atribúty I-Shift v A, I-Shift v M, I-Shift v P a Zatiaženie motora vo viac ako 98% obsahovali rovnaké hodnoty). V ďalšom kroku sme si atribút Miesto rozdelili na Štát, Mesto, Oblasť a Ulicu a odstránili sme tie záznamy, ktoré neobsahovali informáciu o konkrétnom meste. Po tejto úprave nám zostalo viac ako 2800 záznamov.

Atribúty, ktoré podávajú informáciu o celkovom hodnotení jazdného štýlu vodiča (Celkové hodnotenie, Predvídanie, Úsporná a Neúsporná jazda, Najvyšší prevodový stupeň, Využitie motora a prevodovky...) boli transformované na intervaly, presne tak, ako to vyhodnocuje systém Dynafleet:

- 80 – 100 = Dobrý výkon,
- 60 – 79 = Priemer,
- 0 – 59 = Potenciál k zlepšeniu.

Ďalším krokom bola diskretizácia na rovnakú hĺbku intervalu, ktorá rozdelila atribút Priemerná spotreba paliva na nasledovne:

- pod 26,3 l/100km
- 26,4 – 31,5 l/100 km
- nad 31,6 l/100 km

3.2 Návrh modelu

Návrh modelu bol realizovaný pomocou softvérového nástroja RapidMiner a programu Visual Studio. Jednalo sa o model Naivného Bayesovského klasifikátora, pomocou ktorého sme určili, ktoré atribúty majú najväčší vplyv na spotrebu paliva. Dáta sme rozdelili na tréningovú a testovaciu množinu v pomere 80:20. Cieľovým atribútom bola Priemerná spotreba paliva. Celková úspešnosť vytvoreného modelu je 67,93%.

V nasledujúcej tabuľke sú zobrazené najvyššie pravdepodobnosti dosiahnutia nízkej spotreby pre najzaujímavejšie atribúty. Napr. ak vodič bude efektívne využívať tempomat, tak s pravdepodobnosťou 91,8% dosiahne nízku spotrebu paliva.

Tab. 1. Kľúčové faktory vplyvajúce na priemernú spotrebu paliva

Attribute	Parameter	do 26.3 ↓
Úsporná jazda	value=Dobrý výkon	0.957
Tempomat	value=Dobrý výkon	0.918
Využitie motora a prevodovky	value=Dobrý výkon	0.908
Najvyšší prevodový stupeň	value=Dobrý výkon	0.907
Voľný dojazd	value=Dobrý výkon	0.765
Prispôsobenie rýchlosti	value=Dobrý výkon	0.743

Vodič ovláda napríklad rýchlosť, zrýchlenie, brzdenie, otáčky motora alebo zaradenie rýchlostného stupňa. Vyhodnotením zozbieraných údajov môže spoločnosť usmerňovať vodičov alebo zistením prípadných nedostatkov predchádzať rôznym neželaným situáciám a taktiež môže zefektívniť ich jazdu. Napríklad efektívnym používaním tempomatu môže vodič dosiahnuť nižšiu spotrebu a dospieť tak k zníženiu celkových nákladov.

Na základe týchto analýz a analýz uvedených v [3] [4] môžeme zostaviť model dodacej trasy, ktorá nám dokáže s určitou pravdepodobnosťou povedať, akú budú mať priemernú spotrebu jednotliví vodiči. Napríklad, na trase Trelleborg (Švédsko) – Rostok (Nemecko), Vodič_I spotrebuje viac ako 31,5 l/100km, Vodič_J spotrebuje do 26,3 l/100 km.

Na základe vykonaných experimentov sme získali poznatky týkajúce sa úspory spotreby paliva. Odporúčania, ktoré by viedli k zníženiu spotreby paliva sú nasledovné:

- zlepšiť neúspornú jazdu – častejšie využívať motorovú brzdu,
- zlepšiť úspornú jazdu – predstavuje dobu, kedy je vozidlo v pohybe a vodič má nohu na plyne,
- minimalizovať použitie brzdového pedálu,
- efektívnejšie využívať tempomat.

4 Záver

Vďaka technikám prediktívneho dolovania dát, sme určili hlavné faktory, ktoré ovplyvňujú priemernú spotrebu paliva. Na základe týchto výsledkov sme navrhli odporúčania pre vodičov, ktoré by viedli k zníženiu spotreby paliva. Následne sme uká-

zali ako takéto výsledky môžu ovplyvniť rozhodovanie o priradení vodiča na plánovanú dodaciu trasu s dôrazom na nízku spotrebu paliva.

Ďalší výskum bude preto zameraný na rozšírenie vytvoreného modelu o ďalšie faktory, ktoré pomôžu pri rozhodovaní o výbere vodiča. Na základe požiadaviek majiteľa firmy navrhne model rozhodovania využívajúceho navrhnuté modely vodiča a dodacej trasy.

Literatúra

1. Çakıcı, Ö.E., Groenevelt, H., Seidmann, A.: Using RFID for the Management of Pharmaceutical Inventory—System Optimization and Shrinkage Control. In: Decision Support Systems. 2011. pp. 842-852, ISSN: 0167-9236.
2. Dutta, D., Bose, I.: Managing a Big Data Project: The Case of Ramco Cements Limited. In: International Journal of Production Economics. 2015. pp. 293-306, ISSN: 0925-5273.
3. Muchová, M., Paralič, J.: Analýza dát za účelom zlepšenia konkrétneho firemného procesu logistickej firmy. In: WIKT&DaZ 2016: Proceedings from Conference. Bratislava: STU, (2016), pp. 299-304, ISBN 978-80-227-4619-9
4. Muchová, M.: Big data analysis in selected logistics process. In: SCYR 2016: Proceedings from Conference. Košice: TU, (2016), pp. 55-57. ISBN 978-80-553-2566-8
5. Systém na komunikáciu s vozidlami Dynafleet Online – Volvo Truck Corporation, dostupné na internete: <http://www.volvotrucks.com/trucks/dynafleet-help/splash/Pages/splash.aspx>
6. [Tan, K.H, Zhan, Y.Z., Ji, G.J., Ye, F., Chang, C.T. Harvesting Big Data to Enhance Supply Chain Innovation Capabilities: An Analytic Infrastructure Based on Deduction Graph. In: International Journal of Production Economics. 2015. pp. 223 – 233, ISSN: 0925-5273.
7. Waller, M. A., Fawcett S. E.: Data Science, Predictive Analytics, and Big Data: A Revolution That Will Transform Supply Chain Design and Management. In: Journal of Business Logistics. 2013. pp. 77-84, ISSN: 2158-1592.
8. Zhong, R.Y., Huang, G.Q., Lan, S., Dai, Q.Y., Chen, X., Zhang, T.: A Big Data Approach for Logistics Trajectory Discovery from RFID-Enabled Production Data. In: International Journal of Production Economics. 2015. pp. 260-272, ISSN: 0925-5273.

PodĎakovanie:

Táto práca bola podporovaná Agentúrou na podporu výskumu a vývoja na základe zmluvy č. APVV-16-0213 a Kultúrnou a edukačnou grantovou agentúrou MŠVVaŠ SR, projekt č. 025TUKE-4/2015.

Annotation:

Decision support system in the logistics can provide managers of logistics companies valuable information needed to make effective decisions. One of the key and often solved tasks in logistics company are not only the question of low fuel economy but also decisions about assignment of truck drivers to planned routes. The aim of the article is to identify the combination of factors that have a key effect on fuel consumption. This paper focuses on data analysis to improve decision-making in the selected logistics process - the selection of truck drivers for planned routes.

Analýza dát za účelom zlepšenia konkrétneho procesu logistickej firmy

A questionnaire survey shows, that in logistics companies and transport companies often miss information system that would facilitate assigning truck drivers on planned routes.