

## 2. ANALITYKA DANYCH BIZNESOWYCH

*Autor: Dejan Mirčetić*

W erze digitalizacji, ze względu na ogromną ilość danych generowanych codziennie, nie ma możliwości wykorzystania tradycyjnej wiedzy i podejść do zarządzania procesami biznesowymi w różnych obszarach, a więc również do zarządzania logistyką i łańcuchami dostaw (Nikolić i in. 2019). Web 2.0, wraz z Przemysłem 4.0, przetwarzaniem w chmurze, Internetem Rzeczy (ang. Internet of Things – IoT), RFID (ang. Radio Frequency Identification) i innymi technologiami cyfrowymi doprowadziły do generowania, przechowywania i przesyłania dużych ilości danych. Wraz ze wzrostem objętości i złożoności danych rośnie również złożoność i czas potrzebny do analizy tych danych i wyciągania z nich wniosków.

Koncepcję Big Data po raz pierwszy wprowadzili Cox i Ellsworth w październiku 1997 r. w artykule biblioteki cyfrowej ACM (Tiwari i in. 2018). Badania nad pojęciem Big Data i jego konceptualizacja ewoluowały nieustannie. Początkowo Big Data charakteryzowała koncepcja 3V, która obejmowała **objętość**, **prędkość** i **różnorodność**, jak omówiono w poprzednim rozdziale. Następnie charakterystyka ta została rozszerzona o koncepcję 5V, obejmującą dwa dodatkowe atrybuty: **prawdziwość i wartość** (Nguyen i in. 2018; Tiwari i in. 2018). Objętość odnosi się do wielkości generowanych danych; objętość danych cyfrowych rośnie wykładniczo (Arunachalam i in. 2018). Różnorodność odnosi się do faktu, że dane mogą być generowane z heterogenicznych źródeł wewnętrznych i zewnętrznych, w formatach ustrukturyzowanych, półustrukturyzowanych i nieustrukturyzowanych (Nguyen i in. 2018). Prędkość odnosi się do szybkości generowania i dostarczania danych, które mogą być przetwarzane w partiach, w czasie rzeczywistym, prawie w czasie rzeczywistym lub w sposób uproszczony (Nguyen i in. 2018). Prawdziwość podkreśla znaczenie jakości danych, ponieważ wiele źródeł danych z natury zawiera pewien stopień niepewności i zawodności (Nguyen i in. 2018). Wartość odnosi się do znajdowania nowej wartości zawartej w danych, która może być wykorzystana do lepszego planowania biznesowego).

Analitika dużych zbiorów danych (ang. Big Data Analytics – BDA) obejmuje dwa wymiary: **Duże zbiory danych ( ang. Big Data – BD)** opisane koncepcją 5V oraz **Analitikę biznesową (ang. Business Analytics – BA)**, która umożliwia uzyskanie wglądu w dane

poprzez zastosowanie statystyki, matematyki, ekonometrii, symulacji, optymalizacji lub innych technik wspomagających organizacje biznesowe w podejmowaniu lepszych decyzji (Wang i in. 2016). Big Data Analytics (BDA) obejmuje wykorzystanie zaawansowanych technik analitycznych służących wyodrębnieniu cennej wiedzy z ogromnych ilości danych o zmiennych typach celem wyciągnięcia wniosków poprzez odkrywanie ukrytych wzorców i korelacji, trendów i innych cennych informacji i wiedzy biznesowej. BDA pozwala na zwiększenie korzyści biznesowych, wydajności operacyjnej i eksplorację nowych rynków, a także stwarza możliwości rozwoju organizacji (Nguyen i in. 2018; Tiwari i in. 2018). BDA znajduje się w obszarze zainteresowania różnych środowisk zarówno akademickich, jak i biznesowych, szczególnie w logistyce i zarządzaniu łańcuchem dostaw

## **2.1. BDA w logistyce i zarządzaniu łańcuchem dostaw**

Łańcuchy dostaw (ŁD; ang. Supply Chains – SC) stanowią sieć firm i zakładów zaangażowanych w przetwarzanie surowców w produkty końcowe, a także w dystrybucję produktów finalnych do klientów końcowych. W łańcuchach dostaw występują przepływy fizyczne, finansowe oraz informacyjne między różnymi firmami. Każdego dnia łańcuchy dostaw stają się coraz bardziej złożone, bardziej rozbudowane i bardziej globalne. Dlatego też, aby pomyślnie wdrożyć i zarządzać istniejącymi procesami w łańcuchach dostaw i ich ciągłym dostosowywaniem do warunków rynkowych, współczesne łańcuchy dostaw wymagają zatrudniania wysoko wykwalifikowanych ekspertów. Aby sprostać tym trudnym zadaniom, eksperci ŁD potrzebują formalnej edukacji, która zapewni im wiedzę i umiejętności z różnych dziedzin, przede wszystkim z logistyki, technologii informatycznych i ekonomii.


ŁD to zbiór elementów fizycznych, ich działań i procesów, poprzez które zachodzi ich interakcja. Elementy fizyczne, które tworzą strukturę łańcucha, stanowią stałą część ŁD. Decyzje dotyczące projektu struktury ŁD podejmowane są na poziomie strategicznym, a na poziomie taktycznym i operacyjnym podejmuje się decyzje dotyczące sposobów i zasad realizacji poszczególnych procesów logistycznych. Projektowanie stałego ŁD i zarządzanie poszczególnymi operacjami wspólnie stanowią zarządzanie łańcuchem dostaw, które definiuje wydajność łańcucha. Zgodnie z tym, ramy zarządzania ŁD składają się z trzech podstawowych elementów: (1) struktur ŁD; (2) procesów biznesowych; (3) i komponentów kontrolnych. Każdy z tych elementów jest bezpośrednio związany z celami ŁD, to znaczy ze stopniem spełnienia wymagań użytkowników końcowych, przy jednoczesnym poszanowaniu krytycznych wymiarów biznesu, które zależą od wydajności na rynku (kluczowe wskaźniki wydajności – ang. Key Performance Indicators – KPI). We współczesnym świecie konkurencja nie odbywa się

już między poszczególnymi organizacjami, ale między całymi łańcuchami dostawy. Efektywne zarządzanie ŁD stało się zatem potencjalnie cennym sposobem zapewniania przewagi konkurencyjnej i poprawy wydajności organizacji. Zarządzanie łańcuchem dostaw jest faktem biznesowym, a logistyka jest najpotężniejszym narzędziem umożliwiającym osiągnięcie ostatecznej przewagi strategicznej.

Firmy znajdują się pod silną presją poprawy planowania i wydajności ŁD z powodu takich czynników, jak rosnąca niepewność i konkurencja. Poprawa wydajności ŁD stała się ciągłym procesem, który wymaga analitycznego systemu pomiaru wydajności. Biorąc pod uwagę liczbę i różnorodność procesów logistycznych i procesów łańcucha dostaw zasoby wykorzystywane do ich realizacji, parametry, które je charakteryzują, jako podstawę do określania wydajności ŁD, wykorzystuje się dużą liczbę danych dotyczących aspektów: geograficznych, czasowych i ilościowych determinantów towarów, środków transportu, transportu – aktywów manipulacyjnych, pojemności magazynów, pracowników itp. Dane generowane poprzez wewnętrzne operacje, a także transakcje z dostawcami i klientami, mogą być wykorzystywane do odkrywania małych zmian, które mogą mieć duży wpływ na organizację pod względem wzrostu wydajności, a nawet oszczędności kosztów. Innymi słowy, ilość danych w każdym ŁD eksploduje z różnych źródeł danych, procesów biznesowych i systemów informatycznych. Wraz ze wzrostem ilości i złożoności danych rośnie również złożoność i czas potrzebny na analizę tych danych i uzyskanie z nich konkretnych informacji. Określanie, monitorowanie oraz poprawa logistyki i wydajności ŁD stają się bardziej złożone i obejmują wiele procesów, takich jak identyfikacja środków, definiowanie celów, planowanie, komunikacja, monitorowanie, raportowanie i sprzężenie zwrotne. W związku z tym konwencjonalne podejścia nie mogą być stosowane do podejmowania decyzji w ramach ŁD i zarządzania łańcuchem dostaw.

W zarządzaniu łańcuchem dostaw rośnie zainteresowanie analityką biznesową, zwaną również **Analityką Łańcucha Dostaw (ang. Supply Chain Analytics – SCA)**. W społecznościach biznesowych i akademickich SCA jest używane zamiennie z terminami takimi jak „analiza dużych zbiorów danych” i „analiza biznesowa” (Srinivasan i Swink, 2018). SCA odnosi się do wykorzystania danych oraz narzędzi i technik ilościowych w celu poprawy wydajności operacyjnej, często uwidocznionej przez takie wskaźniki, jak realizacja zamówień i elastyczność. Analityka w ŁD nie jest koniecznie nowym pomysłem, ponieważ różne techniki ilościowe i metody modelowania są od dawna stosowane w firmach produkcyjnych. Ostatni wzrost zainteresowania analityką łańcucha dostaw wiąże się z nowymi wyzwaniami i możliwościami zarówno w środowiskach biznesowych, jak i informatycznych. Wyzwania te

obejmują kwestie wynikające z zarządzania dużymi ilościami danych (np. dostępność i jakość danych) oraz radzenia sobie z niepewnością środowiskową. Prawidłowo stosowana SCA może mieć wpływ na kilka obszarów w ŁD i może generować znaczące korzyści w zakresie wydajności logistyki: usprawnione planowanie i harmonogramowanie; poprawiona responsywność; usprawnione planowanie popytu; optymalizacja zamówień; zoptymalizowane zarządzanie zapasami; poprawione planowanie uzupełniania zapasów. W ostatnich dekadach, na skutek rozwoju technologicznego, globalizacji i coraz bardziej wymagających klientów, zmieniły się również paradygmaty biznesowe. Na Rysunku 2.1 przedstawiono typowe okresy (z krótkim opisem) w ewolucji logistyki, SCM i BDA.




**Rysunek 2.1 Ewolucja logistyki, SCM i BDA**

Źródło: Arunachalam, Kumar & Kawalek (2018)

## 2.2. Narzędzia w Analityce Danych Biznesowych

Rysunek 2.2 przedstawia różne trendy, narzędzia i korzyści stosowane w BDA lub SCA. Wszystkie zaprezentowane techniki analityczne można podzielić na trzy typy: opisowe, predykcyjne i preskryptywne (ściśle powiązane z normami). **Analitika opisowa** analizuje dane i zdarzenia z przeszłości, aby określić jakie podejście zastosować w przyszłości. Poszukuje odpowiedzi co do przeszłych porażek i sukcesów. **Analitika predykcyjna** wykorzystuje dane historyczne, aby określić prawdopodobny przyszły wynik zdarzenia lub prawdopodobieństwo wystąpienia sytuacji. Wykorzystuje wzorce znalezione w danych, aby zidentyfikować przyszłe ryzyka i możliwości. **Analitika preskryptywna** automatycznie syntetyzuje Big Data, reguły biznesowe i uczenie maszynowe, aby tworzyć przyszłe prognozy. Wykracza poza

przewidywanie przyszłości, sugerując działania, które należy podjąć, aby osiągnąć pożądane cele. Jest ona również w stanie zademonstrować implikacje każdej możliwej decyzji i działać jako narzędzie wspomagające podejmowanie decyzji dla ekspertów ŁD. W poniższych podrozdziałach przedstawimy i opiszemy różne narzędzia analityczne stosowane w BDA w SCM. Ponadto skupimy się na strategiach zwiększania wiedzy w zakresie BDA dla ekspertów ŁD XXI wieku, poprzez kilka studiów przypadków.



**Rysunek 2.2 Trendy, narzędzia i korzyści SCA**

Źródło: Opracowanie własne

### 2.2.1. Analitka opisowa

Analitka opisowa zapewnia podsumowanie statystyk opisowych dla danej próbki danych, na przykład: średnia, moda, mediana, zakres, histogram i odchylenie standardowe. Analitka opisowa wskazuje, co wydarzyło się w przeszłości i wyprowadza informacje pochodzące ze znacznych ilości danych, aby odpowiedzieć na pytanie, co się dzieje w danej organizacji. Na podstawie informacji w czasie rzeczywistym o lokalizacjach i ilościach towarów w łańcuchu dostaw menedżerowie podejmują decyzje na poziomie operacyjnym (np. dostosowują harmonogram wysyłek, rozmieszczają pojazdy, składają zamówienia na uzupełnienie zapasów produktów itp.) (Souza, 2014). Analitka ta próbuje identyfikować szanse i problemy wykorzystując internetowy system przetwarzania analitycznego i narzędzia wizualizacji wspierane przez informacje dostarczane w czasie rzeczywistym, a także technologię raportowania (np. GPS, RFID, kod kreskowy transakcji). Typowymi przykładami analityki opisowej są raporty, które dostarczają historycznych spostrzeżeń dotyczących produkcji, finansów, operacji, sprzedaży, finansów, zapasów i klientów firmy (Tiwari i in. 2018).

### 2.2.2. Analitka predykcyjna

Analitka predykcyjna wykorzystuje dane historyczne do określenia prawdopodobnego przyszłego wyniku. Analitka predykcyjna w łańcuchach dostaw wyprowadza prognozy popytu

z danych historycznych i odpowiada na pytania dotyczące tego, co się wydarzy lub co prawdopodobnie się wydarzy (Tiwari i in. 2018). Wykorzystuje sztuczną inteligencję, algorytmy optymalizacji i systemy eksperckie do przewidywania przyszłych zachowań na podstawie wzorców odkrytych w przeszłości, a także założenia, że zdarzenia historyczne się powtórzą. Wykorzystuje również wzorce zaszyte w danych do identyfikacji przyszłych ryzyk, możliwości optymalizacji oraz przewidywania przyszłości. Służy ona do uzupełniania brakujących informacji i eksplorowania wzorców danych za pomocą statystyki, symulacji i programowania.

### 2.2.3. Analityka preskryptywna

Analityka preskryptywna wyprowadza rekomendacje decyzyjne na podstawie modeli analityki opisowej i predykcyjnej, a także optymalizacji matematycznej, symulacji lub technik podejmowania decyzji wielokryterialnych. Wykracza poza przewidywanie przyszłych wyników, sugerując również działania, które przyniosą korzyści na podstawie przewidywań, pokazując decydentowi implikacje każdej opcji decyzyjnej. Analityka preskryptywna odpowiada na pytanie, co powinno się wydarzyć.

## 2.3. Otoczenie BDA


Głównym celem ekosystemu BDA jest dostarczanie wartości dla decydenta. W związku z tym podstawowym celem BDA jest udostępnienie wglądu w procesy biznesowe i dostarczenie odpowiedzi na temat tego, w jaki sposób obniżyć koszty i zwiększyć poziom obsługi dla klientów końcowych. Aby zrealizować swój cel, rozwiązania BDA są zwykle dostarczane w formie systemu wspomagania decyzji (ang. Decision Support System – DSS) lub systemu eksperckiego (ang. Exper System – ES). Dlatego w tym i kolejnych rozdziałach skupimy się na kluczowych filarach BDA: **danych biznesowych**, **eksploracji danych** i **odkrywaniu wiedzy** (analiza danych, DSS, platformy ES itp.).

### 2.3.1. Dane biznesowe

Koncepcja danych jest szczegółowo wyjaśniona w pierwszym rozdziale tej książki. Dane są kluczowym czynnikiem do przeprowadzania wszelkiego rodzaju analiz. **Dane biznesowe** są generowane w wyniku wykonywania procesów w danym środowisku biznesowym. W przypadku ŁD istnieje wiele procesów i podprocesów zaangażowanych w dostarczanie usług klientowi ostatecznemu (Rysunek 2.3).

Rysunek 2.3 przedstawia strukturę ŁD, gdzie w przypadku SCA każdy z podanych procesów można obserwować jako generator danych biznesowych. Wygenerowane dane

różnią się pod względem znaczenia i wpływu na ostateczne cele przedsiębiorstwa. W związku powyższym dane biznesowe można podzielić na dane **napędzane wewnątrznie** i **zewnątrznie**. Dane napędzane wewnątrznie to dane, które pojawiają się w wyniku struktury przedsiębiorstwa, hierarchii i sposobu, w jaki organizacja zdecydowała się działać (na przykład dane produkcyjne, dane dotyczące zasobów ludzkich, dane dotyczące dostaw, dane księgowe itp.). Dane te są różne dla każdego przedsiębiorstwa i służą do raportowania, analizowania i sprawozdawczości prawnej dla władz (dane księgowe). Interesującym jest również fakt, że firmy bezpośrednio kontrolują i wpływają na te dane, co czyni je istotnymi jedynie dla tej konkretnej organizacji.




**Rysunek 2.3 Ewolucja logistyki i łańcuchów dostaw**

Źródło: Hesse & Rodrigue (2004)

Dane zewnętrzne odnoszą się do danych generowanych poza organizacją, które mogą być ogólnodostępne, niestrukturyzowane lub zbierane przez organizacje zewnętrzne (dane prywatne). Dla analityków ŁD szczególnie istotne są dane zewnętrzne udostępniane między ogniwami w łańcuchach dostaw, w tym dane o popycie rynkowym. Są one istotne, ponieważ stanowią wynik reakcji rynku na produkty i usługi firmy. Organizacja nie ma bezpośredniego wpływu na te dane, chociaż firmy próbują pośrednio poprawić reakcję rynkową klientów wykorzystując procesy popytowe i ich podprocesy w postaci planowania popytu. Ponadto przedsiębiorstwa próbują modelować udział w rynku swoich produktów za pomocą działań planowania popytu, takich jak pakowanie, promowanie produktu, przeprowadzanie promocji sprzedaży, korzystanie z kilku kanałów dystrybucji itp.

Firmy inwestują dużo czasu, pieniędzy i wysiłku, aby lepiej zrozumieć i modelować swoje procesy zgodnie z danymi o popycie rynkowym. Z kilku powodów jest to bardzo trudne zadanie. Przede wszystkim firmy muszą określić infrastrukturę, procedury i umowy ze sprzedawcami detalicznymi, aby móc śledzić i rejestrować dane o popycie. Zazwyczaj firmy wykorzystują dane o sprzedaży gromadzone od partnerów na dole łańcucha (downstream) jako dane zastępcze dla danych o popycie. W rzeczywistości nie są to dane o popycie, a raczej dane o zakupach, które mogą znacznie zniekształcić informacje na temat popytu. Taka praktyka jest bardzo powszechna, ponieważ firmy niechętnie udostępniają swoje dane. Jednakże praktyka ta jest niewłaściwa, o czym duża część organizacji nie wie. Jedną z wad tego podejścia jest fakt, iż powoduje ono efekt byczego bicia (ang. bullwhip effect) wśród partnerów w ramach łańcucha dostaw. Innym podejściem do gromadzenia danych jest wykorzystanie danych z punktów sprzedaży (ang. point of sale – POS) sprzedawców detalicznych jako danych zastępczych dla danych popytowych (Syntetos i in., 2016). To podejście ma to również swoje zalety i wady, ponieważ nie bierze pod uwagę sytuacji braku towaru na półkach sklepowych. Takie działanie wymaga również stworzenia silnej infrastruktury informatycznej i umów ze sprzedawcami detalicznymi.


Drugim „problemem” wiążącym się z danymi generowanymi przez rynek jest fakt, że nie podążają one za zwykłymi procesami generowania statystyk. Stanowi to pewną trudność, ponieważ większość metod matematycznych i statystycznych zakłada, że dane podążają za pewnym procesem generowania statystyk. Jest to szczególnie zauważalne w ŁD, gdzie modele dotyczące zapasów zakładają, że popyt w okresie realizacji zamówienia podąża za rozkładem normalnym, a do obliczania zapasu bezpieczeństwa należy wykorzystać równania opierające się także o rozkład normalny. Według Mirčetića i in. (2017), Mirčetića i in. (2022) oraz Mirčetića i in. (2018), 90% danych z puli 97 serii w badaniu empirycznym przemysłu piwowarskiego nie podąża za rozkładem normalnym. Ponadto modele obliczania wielkości zapasów zakładają, że popyt jest deterministyczny i równomiernie rozłożony we wszystkich okresach, a w rzeczywistości tak nie jest. Na przykład na Rysunku 2.4 przedstawiono popyt na wstępnie pokrojone salami dla włoskiego producenta w okresie 2015-2022. Popyt wykazuje wyraźne zachowanie niedeterministyczne, tj. stochastyczne (z losowymi wahaniami i trendem).



**Rysunek 2.4 Popyt na wstępnie pokrojone salami w plastrach w latach 2015-2022**

Źródło: Opracowanie własne

Ponadto dzienne zapotrzebowanie wykazuje bardzo zmienne zachowanie, dlatego agregacja zapotrzebowania w różnych horyzontach czasowych (tygodniowym, miesięcznym itd.) charakteryzuje się wyraźnym trendem galopującego popytu (Rysunek 2.5).




**Rysunek 2.5 Agregacja popytu w różnych horyzontach czasowych**

Źródło: Opracowanie własne

Agregacja popytu pokazuje wyraźną nową rzeczywistość od początku COVID-19 (wzrostowy trend w procesie popytu konsumpcyjnego)! To niezbitý dowód na to, że popyt nie jest deterministyczny. Jeśli chodzi o założenie normalności, Rysunek 2.6 pokazuje znaczną

rozbieżność od rozkładu normalnego, mając na uwadze, że jest to rozkład skrajnie asymetryczny prawostronnie.

Rysunek 2.6 pokazuje, że popyt na salami uległ znacznej zmianie od początku pandemii COVID-19. Pierwszy lockdown we Włoszech miał miejsce 21.02.2020 (pionowa czerwona linia na Rysunku 2.4), po którym popyt na wstępnie pokrojone salami gwałtownie wzrósł i osiągnął historyczne maksimum. Popyt stale się zmieniał, osiągając najwyższy wzrost w dniu 20.12.2021, kiedy to sprzedano 21280 pokrojonych sztuk w ciągu jednego dnia.



**Rysunek 2.6 Empiryczny rozkład popytu**

Źródło: Opracowanie własne

Oprócz problemów z wyżej wymienionymi założeniami teoretycznymi dotyczącymi danych, obecna sytuacja w światowej gospodarce, a w konsekwencji w ramach łańcuchów dostaw, stawia przed analitykami biznesowymi kolejne pytania. Pytania te pojawiają się w wyniku pandemii, kryzysów wojennych, niedoborów zasobów, rosnącej inflacji, załamania światowych łańcuchów dostaw itp. Pytanie, które współcześni analitycy biznesowi muszą rozwiązać, zajmując się danymi wygenerowanymi po rozpoczęciu 2019 roku, brzmi: Jak długi okres i horyzont danych są teraz istotne dla obserwacji i modelowania? Widać to wyraźnie na Rysunku 2.4. Jeśli przyjrzymy się bliżej rysunkowi, zauważymy, że przed pandemią COVID-19 i lockdownem konsumenci nigdy nie spożywali wstępnie pokrojonego salami w ilościach takich jak od pierwszego lockdownu. Można zauważyć, że spożycie danego produktu gwałtownie wzrosło. Teraz pojawia się kilka pytań:

- Czy to tylko moda na konsumpcję spowodowana specyficznymi warunkami podczas pandemii?
- Czy ten trend utrzyma się w przyszłości i firma będzie musiała zwiększyć produkcję?
- Czy dane sprzed COVID-19 (z lat 2015-2020) mają dziś jakąkolwiek wartość i czy należy je uwzględnić przy modelowaniu danych dotyczących popytu na wstępnie pokrojone salami?

Są to bardzo trudne pytania, na które nie da się odpowiedzieć bez odpowiedniej procedury analizy danych, która zostanie przedstawiona w kolejnych Rozdziałach.

# BIBLIOGRAFIJA

1. Arunachalam, D., Kumar, N. & Kawalek, J. P. (2018). Understanding big data analytics capabilities in supply chain management: Unravelling the issues, challenges and implications for practice. *Transportation Research Part E*, 114, s. 416-436.
2. Hesse, M. & Rodrigue, J.-P. (2004). The transport geography of logistics and freight distribution. *Journal of Transport Geography*, 12(3), s. 171–184.
3. Mircetic, D., Rostami-Tabar, B., Nikolicic, S. & Maslaric, M. (2022). Forecasting hierarchical time series in supply chains: an empirical investigation. *International Journal of Production Research*, 60(8), pp. 2514-2533.
4. Mirčetić, D. (2018). Unapređenje top-down metodologije za hijerarhijsko prognoziranje logističkih zahteva u lancima snabdevanja (Doctoral dissertation), University of Novi Sad, Serbia.
5. Mirčetić, D., Nikoličić, S., Stojanović, Đ. & Maslarić, M. (2017). Modified top-down approach for hierarchical forecasting in a beverage supply chain. *Transportation Research Procedia*, 22, s. 193-202.
6. Mirčetić, D., Ralević, N., Nikoličić, S., Maslarić, M. & Stojanović, Đ. (2016). Expert system models for forecasting forklifts engagement in a warehouse loading operation: A case study. *Promet-Traffic&Transportation*, 28(4), s. 393-401.
7. Nikoličić, S., Maslarić, M., Mirčetić, D. & Artene, A. (2019). Towards more efficient logistic solutions: Supply chain analytics. In *Proceedings of the 4th Logistics International Conference*, Belgrade, Serbia (s. 23-25).
8. Souza, G. C. (2014). Supply chain analytics. *Business Horizons*, 57, s. 595-605.
9. Srinivasan, R. & Swink, M. (2018). An investigation of visibility and flexibility as complements to supply chain analytics: an organizational information processing theory perspective. *Prod. Oper. Manag.* 27(10), s. 1849–1867.
10. Syntetos, A. A., Babai, Z., Boylan, J. E., Kolassa, S. & Nikolopoulos, K. (2016). Supply chain forecasting: Theory, practice, their gap and the future. *European Journal of Operational Research*, 252(1), s. 1-26.
11. Tiwari, S., Wee, H. M. & Daryanto, Y. (2018). Big data analytics in supply chain management between 2010 and 2016: Insights to industries. *Computers & Industrial Engineering*, 115, s. 319-330.

12. Wang, G., Gunasekaran, A., Ngai, E. W. T. Papadopoulos Th. (2016). Big data analytics in logistics and supply chain management: Certain investigations for research and applications. *Int. J. Production Economics*, 176, s. 98-110.
13. Zhu, S., Song, J., Hazen, B. T., Lee, K. & Cegielski, C. (2018). How supply chain analytics enables operational supply chain transparency: An organizational information processing theory perspective. *International Journal of Physical Distribution & Logistics Management*, 48(1), s. 47-68.