



## Wykorzystanie nowych narzędzi analitycznych w zarządzaniu łańcuchami dostaw – studium przedsiębiorstwa LOKAD

**Arkadiusz Brandt**

Uniwersytet Ekonomiczny w Katowicach

arkadiusz.brandt@gmail.com, ORCID: 0009-0004-8041-5886

**Streszczenie:** Zarządzanie łańcuchami dostaw w erze współczesnej wymaga stosowania zaawansowanych narzędzi i metodologii, aby sprostać dynamicznym wyzwaniom rynkowym. Celem artykułu jest przedstawienie dwóch modeli referencyjnych w zarządzaniu łańcuchami dostaw: SCOR (Supply Chain Operations Reference) oraz GSCF (Global Supply Chain Forum). Artykuł skupia się na tym, jak wykorzystanie narzędzi big data i data science może wzmocnić te modele, umożliwiając lepsze monitorowanie, optymalizację procesów i reakcję na zmiany rynkowe. Zastosowanie tych metod w rzeczywistych środowiskach biznesowych zostało przedstawione na przykładzie implementacji technologii analizy danych w firmie LOKAD. Wyniki rozważań pokazują, że analiza danych w czasie rzeczywistym pozwala na precyzyjne prognozowanie popytu, optymalizację zapasów i identyfikację ryzyka. Na poziomie operacyjnym i taktycznym narzędzie big data może być wykorzystywane do optymalizacji tras pojazdów, zarządzania flotą, poprawy obsługi klienta i rekomendacji produktów. Na poziomie strategicznym big data wspiera projektowanie produktów, planowanie sieci i strategię biznesową.

**Słowa kluczowe:** big data, data science, zarządzanie łańcuchami dostaw, SCOR, GSCF, Supply Chain Scientist.

**Kod JEL:** C8.

## 1. Rola big data i data science w optymalizacji zarządzania łańcuchami dostaw

“Data! data! data!” he cried impatiently. “I can’t make bricks without clay”.

Arthur Conan Doyle, *Sherlock Holmes*

W świecie postępującej globalizacji, nowych technologii internetowych, outsourcingu i rosnącej siły klienta firmy musiały szukać nowych źródeł przewagi konkurencyjnej. Takim źródłem przewagi konkurencyjnej okazały się możliwości i zasoby ich partnerów w łańcuchu dostaw. Zrozumienie tego przyczyniło się do powstania zarządzania łańcuchami dostaw (SCM, ang. Supply Chain Management) wyróżniającego się trzema elementami. To, po pierwsze, szerokie spojrzenie na zarządzanie operacjami logistycznymi. Zarządzanie łańcuchami dostaw wymaga, aby wydajność logistyki była mierzona względem ogólnych celów łańcucha dostaw. Ta zewnętrzna orientacja umożliwia organizacjom skupienie się na planowaniu strategicznym, strukturach organizacyjnych i wskaźnikach wydajności wokół siły ich funkcji logistycznych. Po drugie, firmy zdały sobie sprawę z możliwości uzyskania przewagi konkurencyjnej poza swoją organizacją. Zintegrowanie firm w łańcuchu dostaw wokół strategii biznesowych pozwala na uzyskanie nowych źródeł wartości rynkowej. Po trzecie, pojawiło się nowe spojrzenie na strategiczne zarządzanie kanałami dostaw. Prawdziwą siłę łańcucha dostaw upatruje się tutaj w wymiarach strategicznych tego łańcucha, a nie w jego wymiarach operacyjnych. Skoordynowana strategiczna działalność firm łańcucha dostaw umożliwia im odkrywanie nowych możliwości rynkowych (Ross, 2015, s. 19).

Współczesne zarządzanie łańcuchami dostaw to „proces decyzyjny związany z synchronizowaniem fizycznych, informacyjnych i finansowych strumieni popytu i podaży przepływających między jego uczestnikami w celu osiągnięcia przez nich przewagi konkurencyjnej i tworzenia wartości dodanej z korzyścią dla wszystkich jego ogniw, klientów oraz pozostałych interesariuszy” (Witkowski, 2003, s. 29). Ze względu na złożoność, z jaką można się spotkać w trakcie zarządzania łańcuchami dostaw, do zagadnień ich dotyczących należy podchodzić z punktu widzenia problemów niedających się łatwo oswoić (ang. wicked problem), uwzględniając w ten sposób działania konkurentów, naszych pracowników, partnerów, dostawców i dynamikę, z jaką ma się do czynienia (Head, 2022, s. 25-26).

Dla rozwiązywania problemów dynamicznych i złożonych potrzebne są teorie i narzędzia, które dają firmom dostateczną elastyczność w reagowaniu w warunkach niepewności. Takimi narzędziami są modele referencyjne SCOR (ang. Supply Chain Operations Reference) i GSCF (ang. Global Supply Chain Forum).

Celem artykułu jest przedstawienie dwóch modeli referencyjnych w zarządzaniu łańcuchami dostaw: SCOR oraz GSCF. Artykuł skupia się na opisanu wykorzystania narzędzi big data i data science do wzmocnienia tych modeli, umożliwiając lepsze monitorowanie, optymalizację procesów i reakcję na zmiany rynkowe, a także przyczyniając się do bardziej efektywnego zarządzania łańcuchem dostaw. Zastosowanie tych metod w rzeczywistych środowiskach biznesowych zostanie przedstawione na przykładzie implementacji technologii analizy danych w firmie LOKAD.

## **2. Modele referencyjne łańcuchów dostaw: SCOR i GSCF**

Model referencyjny operacji łańcucha dostaw SCOR jest metodyką, która zawiera narzędzia pozwalające na diagnostykę i analizę porównawczą, tym samym wspierając organizacje we wprowadzaniu radykalnych modyfikacji w łańcuchu dostaw, takich jak planowanie, zaopatrzenie, produkcja, dystrybucja i zwroty. Model SCOR to metoda porównywania i pomiaru ulepszeń w wydajności łańcucha dostaw, co pozwala na ciągłe doskonalenie i efektywne zarządzanie nim (Association for Supply Chain Management, 2017).

Na pierwszym poziomie modelu SCOR, czyli najwyższym poziomie procesów, określa się różne rodzaje procesów oraz cele wydajności na poziomie przedsiębiorstwa lub jednostki. W tym miejscu organizacja określa swoją pozycję konkurencyjną i strategię operacyjną, uwzględniając wymagania dotyczące wydajności, wskaźniki wydajności, karty wyników łańcucha dostaw oraz analizę luki i plan projektu. Ten poziom uwypukla pięć odrębnych procesów zarządzania: Planowanie, Zaopatrzenie, Produkcję, Dostawę i Zwroty. Na poziomie drugim, czyli poziomie konfiguracji, określa się kategorie procesów, które mogą być składnikami łańcucha dostaw. Organizacje mogą konfigurować swoje rzeczywiste operacje z użyciem tych procesów. Każdy produkt może mieć swój własny łańcuch dostaw, który może wymagać konfiguracji. Poziom drugi umożliwia analizę „co by było, gdyby” i ocenę wpływu potencjalnych ulepszeń. Poziom trzeci, czyli poziom elementów procesu, dostarcza informacji wymaganych do skutecznego planowania i ustalania celów poprawy łańcucha dostaw. Określa

on elementy procesu obejmujące wejścia i wyjścia, wskaźniki wydajności, najlepsze praktyki, jeśli są stosowane, oraz zdolności systemowe potrzebne do wsparcia najlepszych praktyk. Ten poziom szczegółowo analizuje informacje i przepływy pracy oraz pomaga w dostosowaniu poziomów wydajności, praktyk i systemów. Poziomy od czwartego wzwyż są specyficzne dla każdej firmy i obejmują strukturę organizacyjną i potrzeby ludzkie, proces oraz technologię. Koncentrują się na implementacji, czyli wdrażaniu konkretnych ulepszeń łańcucha dostaw w życie (Paul & Iyengar, 2004, s. 230-231).

Z kolei GSCF (Global Supply Chain Forum) jest modelem referencyjnym opracowanym przez grupę akademików i praktyków z różnych krajów. Model został opracowany przez Globalne Forum ds. Łańcuchów Dostaw, którego dyrektorem jest znany badacz łańcuchów dostaw Douglas M. Lambert, co częściowo wyjaśnia popularność tego modelu. Ten model koncentruje się na strategicznym podejściu do zarządzania łańcuchem dostaw, skupiając się na takich kwestiach, jak integracja, współpraca między partnerami, innowacje i elastyczność. GSCF pomaga organizacjom w budowaniu strategicznych relacji z dostawcami, klientami i innymi uczestnikami łańcucha dostaw, co umożliwi lepszą reakcję na zmienne warunki rynkowe i zapewni przewagę konkurencyjną. Model GSCF zarządzania łańcuchem dostaw identyfikuje osiem kluczowych procesów biznesowych: zarządzanie relacjami z klientami, obsługa klienta, zarządzanie popytem, wykonywanie zamówień klientów, zarządzanie przepływem produkcji, zarządzanie relacjami z dostawcami, rozwój i wprowadzenie produktów na rynek oraz zarządzanie zwrotami. W modelu GSCF koncepcja „cross-funkcjonalności i cross-firmowości” oznacza, że każdy z tych procesów biznesowych obejmuje wszystkie obszary funkcjonalne w ramach łańcucha dostaw, łącząc je i integrując nawet poza granicami jednego przedsiębiorstwa (Merzlyak, 2015, s. 4103-4104).

Narzędzia big data i techniki data science mogą być wykorzystane do optymalizacji kluczowych obszarów SCOR. W obszarze planowania analiza dużych zbiorów danych historycznych dotyczących sprzedaży, trendów rynkowych, danych demograficznych i innych czynników może pomóc w precyzyjnym prognozowaniu popytu na produkty. Dla zaopatrzenia dane dotyczące przepływu towarów w magazynach, takie jak dane dotyczące położenia towarów, czasu przechowywania i częstotliwości rotacji, mogą być analizowane z zastosowaniem technik data science, aby zoptymalizować układ magazynu i minimalizować koszty przechowywania. Optymalizacja procesów produkcyjnych może być wspierana analizą danych dotyczących procesów produkcyjnych, takich jak informacje o wydajności maszyn, czasach przestojów i zużyciu surowców. Dane

związane z transportem, dostawami, kosztami i jakością usług mogą być analizowane z użyciem narzędzi big data i data science, aby zwiększyć efektywność łańcucha dostaw poprzez optymalizację tras czy też redukcję kosztów transportu.

Analiza danych i techniki data science mogą być również przydatne w obszarach analiz GSCF. Mogą być wykorzystywane do prognozowania popytu na produkty, optymalizacji zapasów poprzez analizę przepływu towarów i kosztów magazynowania, zarządzania ryzykiem związanym z dostawami, optymalizacji tras i sieci logistycznych oraz identyfikacji trendów rynkowych poprzez analizę danych zewnętrznych. Te narzędzia pozwalają na lepsze planowanie, redukcję kosztów i zwiększenie satysfakcji klienta.

Podsumowując, modele referencyjne SCOR i GSCF są niezwykle istotnymi narzędziami dla organizacji w zarządzaniu łańcuchem dostaw, a wykorzystanie narzędzi big data i data science może znacząco wzmocnić ich skuteczność i przyczynić się do osiągnięcia lepszych wyników operacyjnych oraz konkurencyjnej przewagi na rynku.

### **3. Big data i data science**

Istnieje wiele definicji big data. Mogą to być zbiory danych, które przekraczają określoną wielkość, lub dane, które są zbyt duże, aby zostać poddany analizie w arkuszach danych, takich jak MS Excel (Corea, 2019, s. 1). Kolejna definicja big data mówi, iż big data to zbiorcze określenie dla zbiorów danych tak dużych lub złożonych, że trudno jest je przetwarzać z użyciem tradycyjnych technik zarządzania danymi, takich jak np. relacyjne systemy zarządzania bazami danych (Cielen, Meysman, & Ali, 2016, s. 1).

Big data w dniu dzisiejszym charakteryzują trzy ważne cechy. Są to duże ilości danych (volume), wymagające dużej szybkości ich przetwarzania (velocity), gromadzone jako wiele różnych typów danych (variety). Charakterystyki często są uzupełniane o jeszcze dwa V i są w związku z tym znane jako pięć V big data. Czwartą cechą big data jest prawdziwość gromadzonych danych (veracity), natomiast piąte V to wartość danych (value), która może się drastycznie różnić, zależnie od tego, jak dane są wykorzystywane (Chen & Hwang, 2017, s. 4).

Zastosowania big data obejmują szeroki zakres dziedzin, w tym nasze domy, miasta, środowisko, systemy energetyczne, handel detaliczny, logistykę, przemysł, rolnictwo, internet rzeczy i opiekę zdrowotną (Bahga & Madiseti, 2019, s. 27).

W 2001 roku statystyk William S. Cleveland przedstawił plan „powiększenia głównych obszarów prac technicznych w dziedzinie statystyki” poprzez zapewnienie większej ilości zasobów do „obliczania z danymi” oraz zaproponował nazwanie nowej dziedziny „nauką o danych” (data science) (Bardy, 2019, s. 302). William Cleveland połączył tzw. data mining, termin spopularyzowany w 1996 roku w artykule pt. *Od eksploracji danych do odkrywania wiedzy w bazach danych* (Fayyad, Piatetsky-Shapiro, & Smyth, 1996), z narzędziami informatycznymi, tworząc nowe pojęcie data science. Nauka o danych jest więc ewolucyjnym rozszerzeniem statystyki, mogącym poradzić sobie z ogromnymi ilościami generowanych danych, dodając do jej repertuaru metody pochodzące z informatyki (Cielen et al., 2016, s. 2).

Dla problematyki podejmowania decyzji bardzo ważne jest pytanie o podstawowe wymiary zarządzania. W teorii zarządzania tymi wymiarami są wymiar strategiczny, wymiar taktyczny oraz wymiar operacyjny (Figurski, Kochański, & Niepsuj, 2019, s. 210-211). Tym wymiarom zarządzania będą odpowiadały poziomy podejmowania decyzji w zarządzaniu łańcuchami dostaw (Snyder & Shen, 2019, s. 4). Poziomom podejmowania decyzji można przypisać odpowiednie narzędzia podejmowania decyzji z oddzielną kategorią narzędzi, którą jest kategoria zajmująca się prognozowaniem i modelowaniem popytu.

Model SCOR jest modelem poziomu operacyjnego i taktycznego podejmowania decyzji, który obejmuje codzienne operacje i zarządzanie bezpośrednimi procesami w łańcuchu dostaw. Natomiast model GSCF odnosi się do poziomu strategicznego podejmowania decyzji, który obejmuje długoterminowe cele i strategię zarządzania łańcuchem dostaw oraz współpracę między różnymi podmiotami w łańcuchu dostaw.

Z modelem SCOR mogą być skutecznie integrowane narzędzia analizy big data wykorzystywane w prognozowaniu popytu dla łańcucha dostaw. W prognozowaniu popytu dla łańcucha dostaw można się oprzeć w pierwszej linii na klasycznych modelach statystycznych wykorzystujących big data, metody statystyczne i techniki programowania komputerowego dla analizy danych (Vandeput, 2021, s. XXII). Klasyczne techniki są jednak uzupełniane o techniki, do których należą np. uczenie maszynowe (Vandeput, 2021, s. 109), analiza klastrowa, algorytm  $k$  najbliższych sąsiadów oraz sztuczne sieci neuronowe (Seydan & Mafakheri, 2020, s. 11-12).

W przypadku wykorzystania big data do podejmowania decyzji na poziomach operacyjnym i taktycznym zauważa się ogromną liczbę zastosowań tych narzędzi. Należą do nich: optymalizacja tras pojazdów (Milicevic & Obradovic,

2018, s. 58), zarządzanie flotą pojazdów (Marr, 2016, s. 75), optymalizacja procesu dostaw ostatniej mili (Anitha & Patil, 2018, s. 35), poprawa obsługi klienta (Ben Ayed, Ben Halima, & Alimi, 2015, s. 314) oraz systemy rekomendacji dla klientów e-commerce (Marr, 2016, s. 288).

W sposób zgodny z modelem GSCF, który odnosi się do strategicznego poziomu podejmowania decyzji, analiza big data może być wykorzystywana do projektowania i rozwoju produktów (Darvazeh, Vanani, & Musolu, 2020, s. 182), strategicznego planowania sieci (Anitha & Patil, 2018, s. 34) oraz dla potrzeb małego biznesu (Marr, 2016, s. 51-52).

Według badania przeprowadzonego przez Accenture (2014) firmy stosujące zdyscyplinowaną strategię wykorzystania big data analytics przyniosły większe zwroty z inwestycji. Jasna i systematyczna strategia wobec big data oraz analiza danych może zapewnić przewagę konkurencyjną i wyższe marże. Na zastosowaniu big data szczególnie zyskują obszary w łańcuchu dostaw, takie jak marketing, zaopatrzenie, transport i magazynowanie (Awwar, Kulkarni, & Marathe, 2018, s. 420).

W rozwoju technologii big data kluczową rolę odegrało oprogramowanie typu open source, umożliwiając szybkie rozprzestrzenianie się tego ekosystemu. Jednym z kluczowych przykładów zastosowania oprogramowania typu open source w rozwoju technologii big data jest Hadoop (Stephenson, 2018, s. 65-69).

Nicolas Vandeput (2021) demonstruje, jak przy minimalnym wysiłku, stosując narzędzia open source, można stworzyć prognozy zbliżone do najbardziej nowoczesnych rozwiązań rynkowych. Otwiera to drogę małym i średnim przedsiębiorstwom do korzystania ze swoich danych w celach prognozowania i optymalizacji łańcuchów dostaw. Dostępność danej technologii nie oznacza natomiast, że wszystkie firmy będą gotowe wprowadzać ją własnymi siłami. Otwiera to pole dla rozwoju firm oferujących usługi wdrożenia i obsługi danej technologii. Firmy znajdujące się na tym rynku oferują tzw. systemy mieszane. Dla zbierania i konsolidacji danych wykorzystują system ERP, infrastruktura znajduje się w chmurze, a produkty powstają z wykorzystaniem oprogramowania open source.

Do takich usługodawców należy omawiany w punkcie czwartym LOKAD oraz jego konkurenci, tacy jak Relex (RELEX Solutions, 2022) pochodzący ze Szwecji współpracujący z Lidl, Media Markt, Auchan, Rossmann, Leroy Merlin i innymi, oraz Smart Software (Smart Software, 2022) z USA wykorzystujący prognozowanie probabilistyczne w prognozach przeznaczonych dla swoich klientów, do których należą m.in. Disneyland Resort, FedEx oraz Hitachi.

## **4. Zarządzanie łańcuchem dostaw z wykorzystaniem narzędzi data science opracowanych przez firmę LOKAD**

LOKAD powstał w Paryżu w 2008 roku jako firma programistyczna o silnym rdzeniu technologicznym i matematycznym. Dla założycieli firmy ważne było wprowadzenie najnowocześniejszej technologii i nauki do planowania łańcuchów dostaw: LOKAD to jeden z pierwszych użytkowników chmury obliczeniowej. To podejście przyczyniło się do tego, iż firma w swojej krótkiej historii przeszła przez kilka generacji technologii prognostycznych w dążeniu do poprawy procesu optymalizacji łańcuchów dostaw.

Pierwszą generacją modeli prognozowania popytu były modele klasyczne. LOKAD wykorzystuje dzisiaj teorię zwaną statystyczną teorią uczenia się (Bousquet, Boucheron, & Lugosi, 2003). Ta teoria obejmuje najnowocześniejsze metody prognozowania, takie jak regresja wektora nośnego (Support Vector Regression), sieci bayesowskie (Bayesian Networks), metody mieszane, metody wzmacniania oraz metaheurystyki, w tym sieci neuronowe lub algorytmy genetyczne. Nadal stosuje się również metody regresji liniowej, średniej ruchomej, wygładzanie wykładnicze i inne klasyczne metody (LOKAD, 2022).

LOKAD zrozumiał jednak, iż największe straty wynikające ze złego oszacowania popytu zachodzą dla wartości ekstremalnych, a nie dla wartości średnich. Przez pojęcie wartości ekstremalnych jest rozumiany ekstremalnie wysoki popyt na produkty prowadzący do braków towarów oraz ekstremalnie niski popyt prowadzący do zalegania towaru w magazynach (Vermorel, 2018, s. 56). Ponieważ prognozy tworzone za pomocą metod klasycznych koncentrują się na wartościach średnich, LOKAD wprowadził drugą generację metod prognozowania, jakimi są prognozy kwantylowe. Metody te polegają na umyślnym wprowadzeniu błędów podczas procesu tworzenia prognozy w celu uzyskania prognozy obejmującej wartości ekstremalne. Rozwiązanie to, będąc kontrintuicyjnym, prowadzi do pogorszenia dokładności prognozy, poprawiając jednak wynik finansowy.

Fakt, że w łańcuchach dostaw ma się do czynienia z wieloma różnorodnymi problemami, które wymagają w prognozowaniu wprowadzania różnych stopni błędów, doprowadził do zastosowania przez LOKAD tzw. siatek kwantylowych. Pozwalają one na generowanie wielu scenariuszy dla wartości ekstremalnych i wartości pośrednich. Ilość scenariuszy jest nieograniczona, co umożliwia zbu-



dowanie listy priorytetów wszystkich decyzji zakupowych. Dla każdej decyzji o zakupie można przeprowadzić kalkulację, która sprowadza się do marży brutto minus koszt zapasów i minus koszt braku zapasów. Wyniki kalkulacji tworzą listę priorytetów zakupów, gdzie każdy produkt pojawia się w wielu liniach. Podczas gdy zakup jednostki produktu Z może być najważniejszą decyzją zakupową, zakup kolejnej jednostki produktu Z może się znaleźć znacznie dalej na liście (LOKAD, 2022).

Technologia siatek kwantylowych pozwala na prognozowanie różnych aspektów łańcucha dostaw, takich jak czasy realizacji dostaw, ceny sprzedaży lub zwroty towaru. Uświadomienie sobie tego faktu pomogło LOKAD w przejściu do czwartej generacji planowania popytu, jaką było prognozowanie probabilistyczne. W prognozowaniu były brane pod uwagę wszystkie możliwe przyszłości i ich prawdopodobieństwa, nie tylko siatka kroków kwantylowych. Umożliwiło to tworzenie różnych typów prognoz dla innych aspektów łańcuchów dostaw, nie tylko samych prognoz popytu (LOKAD, 2022).

Metody probabilistyczne zostały zapoczątkowane przez US Weather Bureau, które w 1965 roku dołączyło prawdopodobieństwa opadów jako standardową część publicznych prognoz pogody. Ekonomia to kolejna wpływowa dziedzina, która objęła prognozowanie probabilistyczne. Bank Anglii (BoE) od 1997 roku wydaje w ramach kwartalnego Raportu o inflacji tzw. wykresy wachlarzowe, czyli probabilistyczne prognozy inflacji. Probabilistyczne prognozy wykorzystują tzw. eksperymenty Monte Carlo, aby stworzyć zbiór prognoz wielopunktowych z użyciem różnych warunków początkowych, przypominające w swoich założeniach teorię chaosu. Prognozowanie probabilistyczne stoi w wyraźnej sprzeczności z prognozami punktowymi, w których prognozę podaje się w kategoriach oczekiwań, a zatem dostarcza się znacznie mniej informacji (Binter, 2012, s. 34-35).

LOKAD, mając do czynienia z różnymi problemami wymagającymi prognozowania, poczuł potrzebę wszechstronnego rozwiązania mogącego działać efektywnie w przestrzeniach wielowymiarowych i tym rozwiązaniem okazało się być deep learning, które jest nastawione na prognozy probabilistyczne.

Ze względu na rodzaj aplikacji tworzonych w środowisku deep learning pakiety narzędzi dla deep learning zawierają jednak wiele funkcji, które nie są przydatne dla celów prognozowania łańcuchów dostaw, a jednocześnie komplikują i spowalniają pracę systemów na nich opartych. Fakt ten był impulsem dla LOKAD do przejścia na kolejny stopień rozwoju, którym stało się programowanie różniczkowe – Differentiable Programming (LOKAD, 2022).

Programowanie różniczkowe wywodzi się z głębokiego uczenia i reprezentuje połączenie dwóch obszarów algorytmicznych: uczenia maszynowego i optymalizacji numerycznej. Programowanie różniczkowe umożliwia jednocześnie optymalizację szeregu scenariuszy łańcucha dostaw, takich jak wspólna optymalizacja cen i zapasów, optymalizacja asortymentu oparta na lojalności, prognozowanie popytu na niestandardowe produkty itp.

W porównaniu z deep learning programowanie różniczkowe zapewnia doskonale wyniki liczbowe przy zaledwie ułamku kosztów ogólnych wyrażających się przez wysiłek pracowników i potrzebne zasoby obliczeniowe (LOKAD, 2022). O przydatności programowania różniczkowego w kontekście optymalizacji łańcuchów dostaw decyduje fakt, iż pozwala ono na wykorzystanie danych pochodzących z łańcuchów dostaw. Dane te są z natury relacyjne, a ich ilość jest ograniczona. W przypadku deep learning komputer uczy się rozwiązywać złożone problemy z użyciem wielkich zbiorów danych. W przypadku programowania różniczkowego celem jest optymalizacja konkretnie postawionego problemu z wykorzystaniem stosunkowo niewielkiej ilości danych. Techniką stosowaną dla zwiększenia wydajności modeli LOKAD jest wprowadzanie w modelach ograniczeń strukturalnych (structural priors), jak np. założenie, że w czasie promocji obroty tylko rosną. Ograniczenia powodują, że modele LOKAD są w mniejszym stopniu zależne od prawa wielkich liczb.

Wymagane zasoby obliczeniowe i tak są ogromne. LOKAD zbudował więc własny ekosystem z takimi elementami, jak: chmura obliczeniowa (cloud computing), swój język programowania (Envision), robotyzacja, powołanie pozycji tzw. naukowca łańcuchów dostaw (Supply Chain Scientist) oraz skupienie się na tzw. czynnikach ekonomicznych wpływających na podejmowane decyzje.

Ze względu na wielkie moce obliczeniowe potrzebne do wykonywania prognoz LOKAD od samego początku swojego istnienia postawił na chmury obliczeniowe, stając się jednym z pierwszych użytkowników takich usług. Partnerem LOKAD w tym obszarze jest Microsoft ze swoją platformą Windows Azure.

W 2014 roku LOKAD rozpoczął prace rozwojowe i testy własnego języka programowania Envision w wewnętrznych projektach firmy i stało się jasne, że wyniki projektów wykorzystujących Envision systematycznie przewyższały wyniki alternatywnych projektów wykorzystujących ogólne języki programowania. Envision nie jest lepszy od innych języków programowania. Platforma LOKAD i Envision doskonale radzą sobie natomiast z konkretnymi wyzwaniami, przed którymi stoi zarządzanie łańcuchem dostaw (LOKAD, 2022).

Kompleksowa robotyzacja jest z kolei składnikiem umożliwiającym urzeczywistnienie całego systemu. Paradoksalnie LOKAD stwierdził, że całkowita robotyzacja procesu tworzenia prognozy przywróciła kontrolę w ręce kadry zarządzającej. W sytuacji braku robotyzacji firmy starają dać sobie radę ze złożonością systemu przez utrzymywanie armii pracowników. Oznacza to, iż chcąc zmienić procesy łańcucha dostaw, firmy muszą się liczyć z horyzontem czasowym sięgającym wielu miesięcy, a nawet lat. Automatyzacja codziennych procesów podejmowania decyzji na poziomie operacyjnym zwiększa kontrolę kadry zarządczej nad całym systemem, przyspieszając reakcję na zmiany (Vermorel, 2018, s. 18).

Naukowiec łańcucha dostaw to osoba łącząca w sobie funkcje specjalisty łańcucha dostaw oraz naukowca do spraw danych. Połączenie tych funkcji było potrzebne, naukowcy do spraw danych nie mieli bowiem dostatecznej wiedzy na temat łańcuchów dostaw, z kolei specjaliści łańcuchów dostaw nie dysponowali wiedzą w obszarze statystyki, informatyki i programowania. Naukowiec łańcucha dostaw to ta osoba, która generuje decyzje mające na celu optymalizację łańcucha dostaw klienta (Vermorel, 2018, s. 65-68). W LOKAD naukowiec łańcucha dostaw jest więc odpowiedzialny za powodzenie całości projektu.

Z punktu widzenia optymalizacji łańcuchów dostaw kluczowe znaczenie mają czynniki ekonomiczne podejmowanych decyzji. Podejście LOKAD do błędu prognozy jest specyficzne. Firma oblicza wpływ decyzji, podejmowanych na podstawie prognozy, na wynik finansowy klientów, a nie procentowe odchylenie prognozy od rzeczywistości. Pomiar dokładności prognozy jako procentowe odchylenie niekoniecznie prowadzi do lepszego wyniku finansowego, co często powoduje zniekształcenie rzeczywistości. Zamiast optymalizować wynik finansowy, w firmach często ślepo optymalizuje się trafność prognozy (Vermorel, 2018, s. 53-54). Jedną z najczęstszych decyzji, jakie są podejmowane, jest decyzja o zakupie kolejnej sztuki wybranego produktu. Prawidłowe ustalenie czynników ekonomicznych dla decyzji zakupowych zawiera się w uwzględnieniu związanych z daną decyzją kosztów i zysków dla danego poziomu popytu (Vermorel, 2018, s. 57).

Do zalet stosowania zaawansowanych metod zarządzania łańcuchami dostaw (SCM) przez LOKAD można zaliczyć znaczące korzyści i efektywniejsze funkcjonowanie. Począwszy od wykorzystania najnowocześniejszych technologii, takich jak chmura obliczeniowa, firma zdobyła przewagę konkurencyjną w procesie optymalizacji łańcuchów dostaw. Przejście przez różne generacje technologii prognostycznych, aż po wykorzystanie metod probabilistycznych i programo-

wania różniczkowego, umożliwiło LOKAD dynamiczne reagowanie na zmienne warunki rynkowe oraz skuteczne prognozowanie wartości ekstremalnych, co przyczyniło się do poprawy wyników finansowych klientów. Również automatyzacja procesów oraz zaangażowanie naukowców łańcucha dostaw umożliwiły firmie skuteczne podejmowanie szybkich decyzji operacyjnych, co z kolei przełożyło się na lepszą kontrolę nad całym systemem i zwiększoną elastyczność w działaniu. Poprzez skoncentrowanie się na czynnikach ekonomicznych w podejmowaniu decyzji zakupowych oraz wykorzystanie specjalistycznych narzędzi LOKAD stworzył efektywny ekosystem, który przyczynił się do optymalizacji działań i osiągnięcia sukcesu w zarządzaniu łańcuchami dostaw.

## 5. Dyskusja i wnioski

Współczesne zarządzanie łańcuchami dostaw ewoluuje w szybkim tempie, napędzane przez dynamiczny rozwój technologiczny. Jednym z kluczowych aspektów tego rozwoju jest rosnące znaczenie analizy big data oraz data science. Wraz z postępowaniem tych technologii pojawiają się nie tylko nowe wyzwania, ale również szanse dla firm, które są gotowe wykorzystać ich potencjał.

Ważnym aspektem rozwoju przedsiębiorstw jest potrzeba posiadania wykwalifikowanych specjalistów, którzy potrafią efektywnie wykorzystać narzędzia analityczne w kontekście zarządzania łańcuchem dostaw. Przedsiębiorstwa coraz częściej dostrzegają znaczenie inwestycji w technologię big data i data science dla utrzymania konkurencyjności. Nowoczesne narzędzia analityczne pozwalają na lepsze zrozumienie procesów w łańcuchu dostaw oraz szybsze podejmowanie trafnych decyzji.

W kontekście przekształceń w zarządzaniu łańcuchami dostaw kluczową rolę odgrywa kultura danych. Wdrażanie kultury opartej na danych umożliwi firmom lepsze wykorzystanie dostępnych zasobów informacyjnych oraz podejmowanie bardziej trafnych decyzji. Zarządzanie wiedzą w łańcuchach dostaw nabiera coraz większego znaczenia, zwłaszcza w kontekście współpracy partnerów w łańcuchu dostaw oraz automatyzacji procesów decyzyjnych. Sztuczna inteligencja, wspomagająca podejmowanie decyzji dla całych łańcuchów dostaw, staje się nieodzownym narzędziem w integracji klientów, dostawców i partnerów.

Analiza wdrożenia technologii big data (BD) i data science (DS) w firmie LOKAD pokazuje, że firma osiągnęła znaczące korzyści i efektywniejsze funkcjonowanie w zarządzaniu łańcuchami dostaw (SCM). Począwszy od wykorzysta-

nia najnowocześniejszych technologii, takich jak chmura obliczeniowa, LOKAD zdobyła przewagę konkurencyjną w procesie optymalizacji łańcuchów dostaw.

Poprzez przejście przez różne generacje technologii prognostycznych firma umożliwiła sobie dynamiczne reagowanie na zmienne warunki rynkowe oraz skuteczne prognozowanie wartości ekstremalnych. Wykorzystanie metod probabilistycznych i programowania różniczkowego pozwoliło na lepsze zrozumienie procesu prognozowania i kontrolę nad nim, co przyczyniło się do poprawy wyników finansowych klientów.

Automatyzacja procesów oraz zaangażowanie naukowców łańcucha dostaw umożliwiły firmie skuteczne podejmowanie szybkich decyzji operacyjnych, co z kolei przełożyło się na lepszą kontrolę nad całym systemem i zwiększoną elastyczność w działaniu. Skupienie się na czynnikach ekonomicznych w podejmowaniu decyzji zakupowych oraz wykorzystanie specjalistycznych narzędzi, takich jak programowanie różniczkowe, stworzyły efektywny ekosystem, który przyczynił się do optymalizacji działań i osiągnięcia sukcesu w zarządzaniu łańcuchami dostaw.

**Arkadiusz Brandt** – analityk planowania popytu. Posiada tytuł magistra logistyki uzyskany na Uniwersytecie Ekonomicznym w Katowicach oraz magistra ekonomii z Ruhr-Universität Bochum. Aktualnie kontynuuje naukę na Flexible Executive MBA w Trinity College w Dublinie. Pracuje w obszarze zarządzania łańcuchem dostaw, analizy danych oraz implementacji systemu SAP S/4HANA. Włada biegle językami angielskim, niemieckim oraz rosyjskim.

## Spis literatury

- Accenture. (2014). <https://newsroom.accenture.com/news/2014/companies-are-satisfied-with-business-outcomes-from-big-data-and-recognize-big-data-as-very-important-to-their-digital-transformation-accenture-study-shows> (dostęp: 12.04.2024).
- Anitha, P., & Patil, M. M. (2018, September). A review on data analytics for supply chain management: A case study. *International Journal of Information Engineering and Electronics Business*, 5, 30-39.
- Association for Supply Chain Management. (2017). APICS Supply Chain Operations Reference Model SCOR. Pobrano z: <https://www.apics.org/docs/default-source/scor-training/scor-v12-0-framework-introduction.pdf?sfvrsn=2> (dostęp: 3.03.2024).
- Awwar, M., Kulkarni, P., & Marathe, A. (2018, September). Big data analytics in supply chain: A literature review. W: *Proceedings of the International Conference on Industrial Engineering and Operations Management*. Washington DC.

- Bahga, A., & Madiseti, V. (2019). *Big data science & analytics. A hands-on approach*. Online: Arshdeep Bahga & Vijay Madiseti.
- Bardy, H. E. (2019, May). The challenge of big data and data science. *Annual Review of Political Science*, 22, 297-323.
- Ben Ayed, A., Ben Halima, M., & Alimi, A. W. (2015, May). Big data analytics for logistics and transportation. *International Conference on Advanced Logistics and Transport (ICALT)*, 4, 311-316.
- Binter, R. (2012). *Applied probabilistic forecasting*. London: The London School of Economics and Political Science.
- Bousquet, O., Boucheron, S., & Lugosi, B. (2003). *Introduction to statistical learning theory*. Pobrano z: [http://www.econ.upf.edu/~lugosi/mlss\\_slt.pdf](http://www.econ.upf.edu/~lugosi/mlss_slt.pdf) (dostęp: 3.09.2022).
- Chen, M., & Hwang, K. (2017). *Big-Data analytics for cloud, IoT and cognitive learning*. Padstow: Wiley.
- Cielen, D., Meysman, A. D. B., & Ali, M. (2016). *Introducing data science*. USA: Manning.
- Corea, F. (2019). *An introduction to data. Everything you need to know about AI, big data and data science*. Cham: Springer Nature Switzerland AG.
- Darvazeh, S. S., Vanani, I. R., & Musolu, F. M. (2020, March). Big data analytics and its applications in supply chain management. W: *New trends in the use of Artificial Intelligence for the Industry 4.0* (s. 175-200). London: IntechOpen.
- Doyle, A. C. (1995). *The complete Sherlock Holmes*. Doubleday.
- Fayyad, U., Piatetsky-Shapiro, G., & Smyth, P. (1996, Fall). From data mining to knowledge discovery in databases. *AI Magazine*, 17(3), 37-54.
- Figurski, J., Kochański, T., & Niepsuj, J. M. (2019). *Ekonomika logistyki. Część 6. Ćwiczenia*. Warszawa: Wojskowa Akademia Techniczna.
- Head, B. (2022). *Wicked problems in public policy*. Palgrave Macmillan.
- LOKAD. (2022). Pobrano z: [www.lokad.com](http://www.lokad.com) (dostęp: 22.09.2022).
- Marr, B. (2016). *Big data in practice. How 45 successful companies used big data analytics to deliver extraordinary results*. Padstow UK: Wiley.
- Merzlyak, A. (2015). Роль информации и стратегии в моделях управления цепями поставок: референтные модели лучших практик, Менцера, GSCF, CPFR, SCOR. *Российское предпринимательство*, 16(22), 4099-4118.
- Milicevic, M., & Obradovic, I. (2018). Big data in the maritime industry. *Nase More*, 65(1), 55-61.
- Paul, A., & Iyengar, N. (2004, March). Measuring the supply chain performance. *Far East Journal of Theoretical Statistics*, 12(2), 227-232.
- RELEX Solutions. (2022). Pobrano z: <https://www.relexsolutions.com> (dostęp: 22.09.2022).

- Ross, D. F. (2015). *Distribution planning and control. Managing in the era of supply chain management*. New York: Springer.
- Seydan, M., & Mafakheri, F. (2020, July). Predictive big data analytics for supply chain demand forecasting: methods, applications and research opportunities. *Journal of Big Data*, 7(53), 1-22.
- Smart Software. (2022). Pobrano z: <https://smartcorp.com> (dostęp: 22.09.2022).
- Snyder, L. V., & Shen, Z.-J. M. (2019). *Fundamentals of supply chain theory*. New Jersey: John Wiley & Sons, Inc.
- Stephenson, D. (2018). *Big data demystified. How to use big data, data science and AI to make better business decisions and gain competitive advantage*. Harlow UK: Pearson Education Limited.
- Vandeput, N. (2021). *Data science for supply chain forecasting*. Berlin: De Gruyter.
- Vermorel, J. (2018). *The quantitative supply chain*. Paris: LOKAD.
- Witkowski, J. (2003). *Zarządzanie łańcuchem dostaw. Koncepcje procedury doświadczenia*. Warszawa: Polskie Wydawnictwo Ekonomiczne.

## The use of new analytical tools in supply chain management – a case study of the company LOKAD

**Abstract:** Supply chain management in the modern era requires the use of advanced tools and methodologies to meet dynamic market challenges. The article presents two key reference models in supply chain management: SCOR (Supply Chain Operations Reference) and GSCF (Global Supply Chain Forum) and focuses on how the use of big data and data science tools can strengthen these models, enabling better monitoring, process optimization, and response to market changes. The article discusses the applications of big data and data science in supply chain management. Real-time data analysis allows for precise demand forecasting, inventory optimization, and risk identification. At the operational and tactical levels, big data can be used for optimizing vehicle routes, fleet management, improving customer service, and product recommendations. At the strategic level, big data supports product design, network planning, and business strategy. Furthermore, the article presents data science tools developed by LOKAD for supply chain management. LOKAD utilizes advanced forecasting methods, including quantile and probabilistic forecasts, to account for extreme values, and the latest approach based on differential programming enabling simultaneous optimization of multiple supply chain scenarios, ensuring excellent numerical results at minimal costs.

**Keywords:** big data, data science, supply chain management, SCOR, GSCF, Supply Chain Scientist.

**JEL Classification:** C8.