

Mgr Mateusz Wyrembek
ORCID: 0000-0002-7946-948X
e-mail: mateusz.wyrembek@gmail.com

Wykorzystanie technologii Big Data do predykcji ryzyka opóźnień w łańcuchu dostaw

The use of Big Data technology to predict the risk of delay in supply chain

Streszczenie

W ostatnich latach coraz większą uwagę poświęca się zastosowaniu technologii Big Data, uczenia maszynowego oraz sztucznej inteligencji (*artificial intelligence* — AI). Przedsiębiorstwa dążą do przewagi konkurencyjnej poprzez odpowiednie zastosowanie analityki danych. Technologia Big Data może być wykorzystywana w wielu różnych branżach, np. w branży transportowej czy medycznej, a potencjalnie we wszystkich. Olbrzymim problem w łańcuchu logistycznym jest ryzyko opóźnień, na które może wpływać wiele czynników, m.in. nieczytelna etykieta na przesyłce, brak pracowników magazynowych czy kongestia w miastach. Artykuł koncentruje się na zastosowaniu technologii Big Data do wykrywania ryzyka opóźnień w łańcuchach dostaw produktów leczniczych. Jego celem jest przedstawienie koncepcji dużych zbiorów danych, architektury Big Data dla łańcucha dostaw produktów leczniczych oraz zaprezentowanie wyników badań związanych z predykcją ryzyka opóźnień dzięki implementacji tej architektury w rzeczywistym przedsiębiorstwie. Postawiony cel zdeterminował wybór następujących metod badawczych: analizy literatury oraz modelowania, które pozwoliło zaprojektować i wdrożyć architekturę dla łańcucha dostaw w badanym przedsiębiorstwie. W ostatniej części artykułu zaprezentowano model regresji logistycznej do przewidywania opóźnień w łańcuchu dostaw produktów leczniczych. W ramach badań ustalono, że model ma wysoką zdolność predykcyjną.

Słowa kluczowe:

Big Data, zarządzanie łańcuchem dostaw, zarządzanie ryzykiem

Abstract

In recent years, more and more attention has been paid to the use of Big data technology, machine learning and AI. Enterprises strive for a competitive advantage through the appropriate use of data analytics. Big data can be used in many different industries, e.g. in the transport or medical industry, and potentially in all of them. A huge problem in the supply chain is the risk of delay, which may be influenced by many factors, including illegible label on the package, lack of warehouse workers or congestion in cities. The article focuses on the use of Big Data technology to detect the risk of delays in the supply chains of medicinal products. Its purpose is to present the concept of Big Data, Big Data architecture for the drug supply and to present the results of research related to the prediction of the risk of delays in its implementation in a real enterprise. The set goal determined the choice of the following research methods: analysis of literature and the use of modeling, which allowed to design and implement the architecture for the drug supply chain to collect data in the studied enterprise. The last part of the article presents a logistic regression model for predicting delays in the supply chain of medicinal products. The research established that the model has a high predictive ability.

Keywords:

Big Data, supply chain management, risk management

JEL: C45, C53, C55, D81, R41

Wprowadzenie

W ciągu kilku ostatnich lat koncepcja Big Data stała się bardzo popularną ideą. Dzisiejsze przed-

siębiorstwa dążą do redukcji kosztów i zwiększenia efektywności swojej działalności operacyjnej. Poszukując przewagi konkurencyjnej, organizacje nawiązują współpracę w ramach łańcucha dostaw. Rozwój technologii informacyjno-komunikacyjnych

(*Information and Communication Technologies — ICT*) pozwolił zarówno na udoskonalenie istniejących, jak i stworzenie nowych narzędzi do wspomagania przedsiębiorstw. Globalna informatyzacja, powszechny dostęp do Internetu oraz coraz większa popularność urządzeń mobilnych spowodowały drastyczny przyrost danych wytworzonych przez ludzkość.

Z roku na rok pojawia się coraz więcej danych. Szacuje się, że w ciągu pięciu kolejnych lat tempo generowania informacji będzie rosło o 23% rocznie (Wyrembek, 2022). W następstwie tego współczesne przedsiębiorstwa będą musiały zmierzyć się z poważnym wyzwaniem, jakim jest osiągnięcie przewagi konkurencyjnej za pomocą analiz olbrzymich i stale zmieniających się zbiorów danych. Analizy, które kiedyś były niemożliwe do wykonania z powodu braku odpowiednich narzędzi czy zbyt małej mocy obliczeniowej komputerów, dziś są wykonywane w prawie każdym przedsiębiorstwie. Ogólnoświatowy dostęp do Internetu i niskie koszty opartych na nim rozwiązań wpłynęły na wzrost dostępu do danych, przez co może z nich korzystać każda organizacja, bez względu na rozmiar.

Technologia Big Data może być wykorzystywana w wielu różnych branżach, a potencjalnie we wszystkich. Branżami, które mogą wykorzystać ową technologię są na przykład branża transportowa czy medyczna. Badanie przeprowadzone przez T. Schoenherra i C. Speier-Pero (2015) na temat obecnego zastosowania analityki w łańcuchu dostaw, jej wyzwań i przyszłego potencjału ujawniło, że 40% ankietowanych organizacji korzystało z analiz, 8,7% planuje korzystać z analityki w przyszłości, a tylko 22% w ogóle nie planowało wdrożenia jakiegokolwiek formy analityki. Najczęstszym powodem jej wykorzystania jest zwiększenie wartości procesu łańcucha dostaw.

Olbrzymim problem w łańcuchu logistycznym jest ryzyko opóźnień, na które może wpływać wiele czynników, m.in. nieczytelna etykieta na przesyłce, brak pracowników magazynowych czy kongestia w miastach. Artykuł koncentruje się na zastosowaniu technologii Big Data do wykrywania ryzyka opóźnień w łańcuchach dostaw produktów leczniczych. Jego celem jest przedstawienie koncepcji dużych zbiorów danych, architektury Big Data dla łańcucha dostaw produktów leczniczych oraz za prezentowanie wyników badań związanych z predykcją ryzyka opóźnień dzięki jej implementacji w rzeczywistym przedsiębiorstwie.

Big Data w logistyce


W dzisiejszym świecie cały czas zwiększa się ilość dostępnych danych. Przedsiębiorstwa przetwarzają je za pomocą komputerów, które następnie przekazują informacje służące m.in. do poprawy sprzedaży, obsługi klienta czy działalności operacyjnej organizacji w celu zwiększenia przewagi konkurencyjnej. Codziennie generowanych jest 2,5 EB danych (Marciniak & Szymczak, 2015, s. 9).

Jak pokazano na rysunku 1, ilość danych wygenerowanych w 2011 r. przekroczyła 1,80 ZB. Prognoza przewiduje, że ludzkość do roku 2025 będzie wytwarzać i reprodukować 175 ZB danych rocznie. Podstawowymi przyczynami tak raptownego przyrostu ilości danych są informatyzacja, dostęp do Internetu oraz nieustanny rozwój generujących je źródeł. M. Ghotkar i P. Rokde (2016) sklasyfikowali te źródła w trzech kategoriach:

- **dane generowane przez urządzenia** — dane wytwarzane w czasie rzeczywistym przez czujniki bez interwencji człowieka, np. komputery samochodowe zbierają informacje o spalaniu auta;

Rysunek 1

Roczny przyrost danych w latach 2010–2025



Źródło: Reinsel i in., 2018, s. 6

■ **dane generowane przez człowieka** — powstają w efekcie działalności ludzi w Internecie czy w mediach społecznościowych, np. przez dodanie tweeta na portalu Twitter;

■ **dane generowane przez przedsiębiorstwa** — informacje wytworzone w efekcie działalności przedsiębiorstwa, np. z systemów ERP.

Ciągle zwiększająca się ilość danych wymaga rozbudowy pamięci, a także usprawniania ich analizy w celu podejmowania lepszych decyzji (Zdrenka, 2017, s. 92).

W literaturze można znaleźć wiele niejednoznacznych definicji Big Data. Termin ten jest nadal stosunkowo nowy, ponieważ określa ideę powstałą pod koniec XX w. Dlatego też nie został jednolicie zdefiniowany (Brzeziński, 2016; Zdrenka, 2017). Jedną z pierwszych definicji przedstawili M. Cox i D. Ellsworth (1997), którzy stwierdzili, że Big Data to: „pojedyncze obiekty danych (lub zbiory), które są zbyt duże, aby mogły być przetwarzane przez standardowe algorytmy i oprogramowanie”. Należy zauważyć, że Big Data obejmuje nie tylko aspekt technologiczny, ale również ekonomiczny. Powyższe stwierdzili D. Reinsel i J. Gantz (2011), którzy postawili tezę, że koncepcja ta to: „nowa generacja technologii i architektury, zaprojektowana w celu pozyskiwania ekonomicznej wartości z bardzo dużych wolumenów szerokiej gamy danych poprzez przechwytywanie, wyszukiwanie i/lub analizę”. Warto też przywołać konkluzję J. Maślankowskiego (2015), który uważa, że: „Big Data można (...) określać w kategoriach instrumentu naukowego nowej generacji. Mogą to być pozornie proste analizy, takie jak badanie zachowań konsumentów na podstawie informacji zamieszczanych w Internecie, jak również złożone algorytmy w zakresie zaawansowanych obliczeń”.

Big Data definiuje się też, bazując na identyfikacji przymiotnikowej (Brzeziński, 2016, s. 24), przez co powstała koncepcja 5V — ilość (*volume*), szyb-

kość (*velocity*), wiarygodność (*veracity*), różnorodność (*variety*) oraz wartość (*value*). W tabeli 1 przedstawiono charakterystykę wymienionych cech.

Jak już wcześniej zostało wspomniane, Big Data to zbiory zbyt duże, aby mogły być przetwarzane w tradycyjny sposób przez oprogramowanie baz danych. Doprowadziło to do rozwoju nowych narzędzi, takich jak np.:

■ **Hadoop** — oprogramowanie umożliwiające przechowywanie i przetwarzanie danych o niskich kosztach i skalowalności (Racka, 2016);

■ **języki Python/R** — języki programowania typu open-source, które mają rozległe i stale rozbudowywane biblioteki do statycznej analizy danych (Wyrembek, 2022, s. 19);

■ **Tableau, Looker i Microsoft Power BI** — produkty służące do opracowywania i wizualizacji interaktywnych pulpitów w sieci Web (Gupta & Kamath, 2021).

Proponowana architektura Big Data

S. Biswas i J. Sen (2016) zaproponowali architekturę Big Data dla łańcucha dostaw opartą na chmurze, która została pokazana na rysunku 2. Celem przedstawionego systemu jest pozyskiwanie, przetwarzanie, magazynowanie, analiza oraz wizualizacja danych na każdym etapie łańcucha dostaw.

Architektura zaproponowana przez S. Biswas i J. Sena (2016) składa się z sześciu elementów:

■ **tagów i innych urządzeń do zbierania danych** — głównym źródłem danych są tagi RFID umieszczone na każdym produkcie, informacje z obiektów przekazywane są do chmury;

■ **chmury obliczeniowej** — zebrane dane są przekazywane do chmury obliczeniowej, w której są przechowywane i mogą być replikowane;

Tabela 1

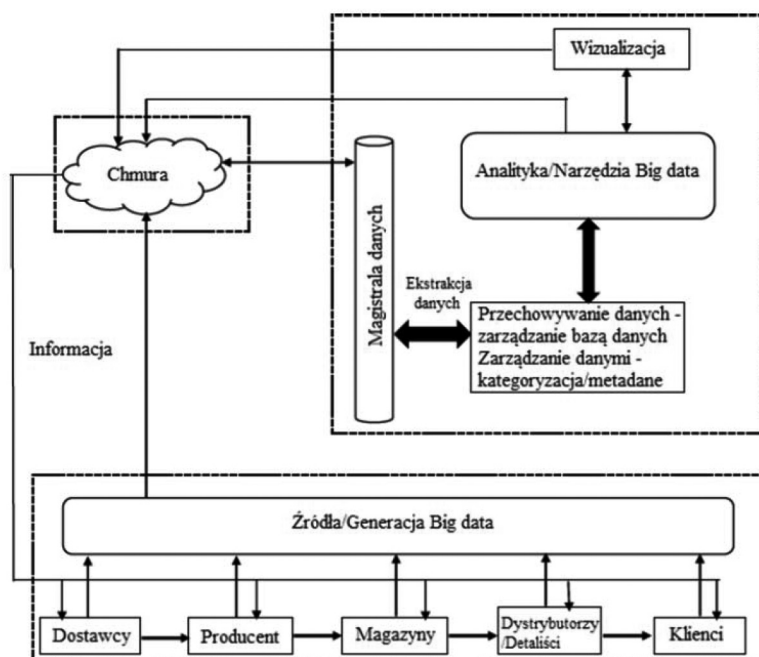
Charakterystyka cech Big Data zgodnie z koncepcją 5V

Cecha	Charakterystyka
Ilość (<i>volume</i>)	Skala danych, czyli ich rozmiar, głównie mierzony w terabajtach i petabajtach
Szybkość (<i>velocity</i>)	Szybkość napływu i przetwarzania ciągle zmieniających się danych, które potrzebują dodatkowej mocy obliczeniowej do analiz w czasie rzeczywistym
Wiarygodność (<i>veracity</i>)	Jakość i dokładność danych
Różnorodność (<i>variety</i>)	Heterogenność danych: ustrukturyzowana, częściowo ustrukturyzowana, nieustrukturyzowana
Wartość (<i>value</i>)	Przydatność danych w podejmowaniu decyzji

Źródło: opracowanie własne na podstawie: Brzeziński, 2016, s. 24–25; Racka, 2016, s. 314–315.

Rysunek 2

Architektura Big Data dla łańcucha dostaw oparta na chmurze



Źródło: Biswas & Sen, 2016, s. 6.

- **magistrali danych** — dane z chmury są odbierane w systemowej magistrali danych na podstawie typu; te, które wymagają przetwarzania i analizy w czasie rzeczywistym, są kierowane przez chmurę do systemu przechowywania i zarządzania danymi w taki sposób, aby występowały minimalne opóźnienia, podczas gdy inne dane mogą być przesyłane tylko wtedy, gdy trzeba je przetworzyć i przeanalizować;
- **systemu przechowywania i zarządzania danymi** — system ten pozwala na przechowywanie, zarządzanie bazą danych oraz wstępne przetwarzanie danych;
- **silnika analizy danych** — silnik analizy zawiera algorytmy, które przetwarzają dane w celu wydobycia z nich nowych informacji;
- **systemu wizualizacji i renderowania danych** — system ten służy do wizualizacji wyników analiz, tak aby użytkownik mógł szybko podjąć decyzję.

Na podstawie pracy przedstawionej przez S. Biswas i J. Sena (2016) zaproponowano własną architekturę opartą na chmurze dla łańcucha dostaw produktów leczniczych (rysunek 3), której zakres ogranicza się do generowania, przechowywania, analizy oraz wizualizacji.

Zaproponowane rozwiązanie również polega na umieszczeniu tagów RFID na produktach. Dane generowane w czasie rzeczywistym trafiają do sys-

temów WMS, TMS oraz ERP, gdzie są centralizowane i organizowane. Wszelkie zebrane dane są umieszczane w chmurze, która je odbiera i przekazuje do bazy danych. Zastosowanie języka R pozwala na wykorzystanie metod uczenia maszynowego, które umożliwiają przewidywanie i pozyskanie informacji, co przekłada się na podejmowanie dobrych decyzji. Następnie analizy są wizualizowane.

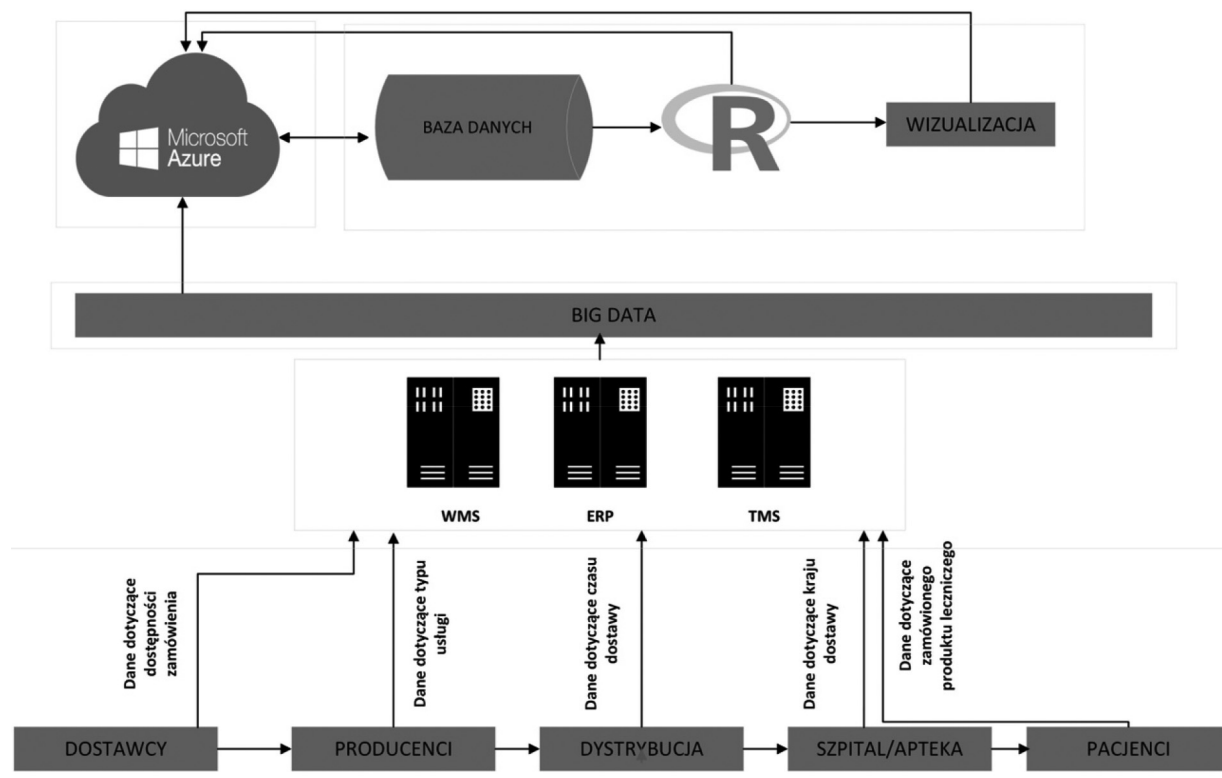
Zastosowanie technologii Big Data w łańcuchu dostaw w celu predykcji opóźnień na przykładzie przedsiębiorstwa X

Zaprezentowana architektura została zaimplementowana w przykładowym przedsiębiorstwie o umownej nazwie X, które działa w branży medycznej. Zebrane informacje stworzyły zbiór danych z 80 400 obserwacjami w 15 kolumnach. Eksperyment został przeprowadzony przy użyciu platformy Microsoft Azure, natomiast głównym językiem programowania był język R.

Do eksperymentu użyto metody regresji logistycznej do klasyfikacji binarnej. Przyjęto założenie, że ryzyko opóźnienia jest realne, co oznacza:

Rysunek 3

Proponowana architektura Big Data dla łańcucha dostaw produktów leczniczych



Źródło: opracowanie własne na podstawie: Biswas & Sen, 2016, s. 6.

$$\text{Ryzyko} = \begin{cases} 0 & \text{dla dostaw terminowych.} \\ 1 & \text{dla dostaw nieterminowych.} \end{cases}$$

Do analizy wybrano zmienne, które znajdują się w tabeli 2. Dane zostały podzielone na dwie części: zestaw uczący (80%) oraz zestaw testowy (20%). Należy również zaznaczyć, że badany zbiór nie ma brakujących wartości.

Model przedstawiony na rysunku 4 został zbudowany za pomocą funkcji glm(). Współczynniki dla predyktorów liniowych zostały oszacowywane przy użyciu estymacji największego prawdopodobieństwa na zbiorze danych uczących się. Funkcja łączenia logit jest używana do przekształcenia szacowanej wartości z predyktorów liniowych do wartości od 0 do 1, która może być zinterpretowana jako prawdopodobieństwo opóźnienia. Wartości p w da-

Tabela 2

Charakterystyka wybranych zmiennych

Zmienna	Charakterystyka
Planowane dni dostawy	Planowany czas od złożenia zamówienia do dostawy do odbiorcy liczony w dniach
Dni dostawy	Rzeczywisty czas od złożenia zamówienia do dostawy do odbiorcy liczony w dniach
Ryzyko	Ryzyko to zmienna binarna: 0 — dostawa terminowa, 1 — dostawa nieterminowa
Kraj	Docelowy kraj dostarczenia towaru
Usługa	Typ usługi transportu oferowany przez przewoźnika: premium — dostawa w ciągu 48 h, standard — dostawa w ciągu 72 h

Źródło: opracowanie własne.

Rysunek 4


Model regresji liniowej

```
##
## Call:
## glm(formula = Ryzyko ~ Dni.dostawy + Dni.planowane.dostawy +
##      Kraj + Usługa, family = binomial(link = "logit"), data = train)
##
## Deviance Residuals:
##      Min       1Q   Median       3Q      Max
## -6.4178  -0.2304  -0.0008   0.0245   2.5958
##
## Coefficients:
##              Estimate Std. Error z value Pr(>|z|)
## (Intercept)    -3.34823    0.06562  -51.026 < 2e-16 ***
## Dni.dostawy      5.86229    0.06083   96.368 < 2e-16 ***
## Dni.planowane.dostawy -5.99879    0.06667  -89.978 < 2e-16 ***
## KrajBE         -0.93970    1.62387   -0.579 0.562807
## KrajCZ         -0.26415    0.07217   -3.660 0.000252 ***
## KrajDE         -0.93433    0.37474   -2.493 0.012657 *
## KrajDK         -0.28612    0.13284   -2.154 0.031254 *
## KrajES         -0.55809    0.65231   -0.856 0.392245
## KrajFR         -0.64926    0.34325   -1.892 0.058555 .
## KrajHR        -7.08130   119.46806   -0.059 0.952734
## KrajHU          0.48718    0.06658    7.317 2.53e-13 ***
## KrajIT        -0.86827    0.50764   -1.710 0.087194 .
## KrajLT        -0.61262    0.54165   -1.131 0.258044
## KrajLU        -2.65120    8.79812   -0.301 0.763157
## KrajLV        -0.42125    0.74603   -0.565 0.572305
## KrajPL        -0.22804    0.10496   -2.173 0.029812 *
## KrajSE         0.15072    0.58014    0.260 0.795020
## KrajSI        -3.30481    8.99826   -0.367 0.713416
## KrajSK        -0.08119    0.17478   -0.465 0.642279
## UsługaStandard  0.27867    0.08156    3.417 0.000633 ***
## ---
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## (Dispersion parameter for binomial family taken to be 1)
##
##      Null deviance: 86977  on 64319  degrees of freedom
## Residual deviance: 12865  on 64300  degrees of freedom
## AIC: 12905
##
## Number of Fisher Scoring iterations: 9
```

Źródło: opracowanie własne.

Rysunek 5

Krzywa ROC



Źródło: opracowanie własne.

nych wyjściowych dają nam również wyobrażenie o tym, jak skuteczna jest każda zmienna predykcji na w przewidywaniu prawdopodobieństwa ryzyka opóźnienia. Dla otrzymanego modelu obliczono miarę R^2 McFaddena, która przyjmuje wartości z przedziału [0; 1]. Pozwala ona ocenić, jak dobrze algorytm pasuje do danych (Pełka, 2015, s. 49). Wartość 0,85 jest bardzo duża jak na miarę R^2 McFaddena, co oznacza, że zbudowany model dobrze pasuje do danych i ma wysoką zdolność predykcijną.

Dla modelu obliczono AUC, które wynosi 0,96163. Miara ta określa jego trafność i przyjmuje wartości z przedziału [0; 1] — czym większa wartość, tym lepsza zdolność predykcyjna (Harańczyk, 2010, s. 84). Krzywa ROC, która przedstawia wydajność modelu, została zobrazowana na rysunku 5. Model ma wysoką zdolność predykcijną.

Podsumowanie

Technologia Big Data i związane z nią rozwiązania mają coraz większe znaczenie dla przedsiębiorstw. Relatywnie niskie koszty Internetu oraz darmowe narzędzia typu open-source (np. język R

czy język Python) umożliwiają wprowadzanie rozwiązań korzystających z dużych zbiorów danych w każdej organizacji gospodarczej. Pozwala to na osiągnięcie przez przedsiębiorstwa przewagi konkurencyjnej. W tym miejscu można przytoczyć słowa P. Norviga, dyrektora ds. badań w Google LLC, który zapytany o źródła sukcesu przedsiębiorstwa, odpowiedział: „to nie lepsze algorytmy, lecz większa ilość danych” (Forbes.com, 2011). Słowa te wskazują, gdzie warto szukać przewagi konkurencyjnej.

W artykule przedstawiono koncepcję dużych zbiorów danych, architekturę Big Data dla łańcucha dostaw produktów leczniczych opartą na chmurze oraz model regresji logistycznej służący do predykcji opóźnionych dostaw. Przedstawiony model ma wysoką zdolność predykcijną.

Przyszłym kierunkiem badań autora będzie zaprojektowanie i zaimplementowanie architektury Big Data dla łańcucha dostaw produktów leczniczych, która uwzględni proces zarządzania ryzykiem. Zebrane dane posłużą do wdrożenia metody uczenia maszynowego. Planowane jest szkolenie klasyfikatorów, aby można było określić, czy dostawa będzie terminowa, czy spóźniona. To pozwoli przewidzieć, czy przyszłe dostawy będą terminowe.

Bibliografia/References

- Biswas, S., & Sen, J. (2016). *A proposed framework of next generation Supply Chain Management using Big Data analytics*. Paper presentation. Proceedings of National Conference on Emerging Trends in Business and Management: Issues and Challenges. 17–18.03.2016. Kolkata, Indie. <https://doi.org/10.13140/RG.2.01.2183.4487>
- Brzeziński, J. (2016). Zarządzanie informacjami jako źródło przewagi konkurencyjnej łańcucha dostaw w kontekście koncepcji Big Data. W: B. Ocicka, & M. Zięba (Red.), *Innowacja w łańcuchach dostaw źródłem przewagi konkurencyjnej w XXI wieku* (21–30). Wydawnictwo Uniwersytetu Łódzkiego. <https://doi.org/10.18778/8088-496-0>
- Cox, M., & Ellsworth, D. (1997). *Managing Big Data for scientific visualization*. ACM Siggraph. https://www.researchgate.net/publication/238704525_Managing_big_data_for_scientific_visualization
- Forbes.com. (2011). *Google's „infringenovation” secrets*. <https://www.forbes.com/sites/scottcleland/2011/10/03/googles-infringenovation-secrets/?sh=10ce156230a6> (pobrano 11.06.2022).
- Ghotkar, M., & Rokde, P. (2016). Big Data: How it is generated and its importance. *IOSR Journal of Computer Engineering*, 1–5. <https://www.iosrjournals.org/iosr-jce/papers/conf.15013/Volume%202/1.%2001-05.pdf?id=7556>
- Gupta, I., & Kamath, M. (2021). *Adding Value to Manufacturing, Retail, Supply Chain, and Logistics Operations with Big Data Analytics*. MHI Solutions Community. <http://www.warehouseautomation.org/2021/07/10/big-data-analytics-and-its-value-across-supply-chain-operations/> (pobrano 11.06.2022).
- Harańczyk, G. (2010). *Krzywe ROC, czyli ocena jakości klasyfikatora i poszukiwanie optymalnego punktu odcięcia*. StatSoft Polska Sp. z o.o. https://media.statsoft.pl/_old_dnn/downloads/krzywe_roc_czyli_ocena_jakosci.pdf (pobrano 28.06.2022).
- Marciniak, M., & Szymczak, M. (2015). Big Data w zarządzaniu łańcuchem dostaw, *Gospodarka Materiałowa i Logistyka*, (7), 8–15.
- Maślankowski, J. (2015). Analiza jakości danych pozyskiwanych ze stron internetowych z wykorzystaniem rozwiązań Big Data. W: A. Sobczak, & A. Kobyliński (Red.), *Technologie informatyczne w administracji publicznej i służbie zdrowia* (167–177). Wydawnictwo Szkoły Głównej Handlowej w Warszawie.
- Pełka, M. (2015). Regresja logistyczna dla danych symbolicznych interwałowych. *Ekonometria*, 2(48), 44–52. <https://doi.org/10.15611/ekt.2015.2.04>
- Racka, K. (2016). Big Data — znaczenie, zastosowania i rozwiązania technologiczne. *Zeszyty Naukowe PWSZ w Płocku. Nauki Ekonomiczne*, 1(23), 311–323.
- Reinsel, D., & Gantz, J. (2011). *Extracting value from chaos*. IDC. https://scholar.google.pl/scholar_url?url=http://www.kushima.org/wpcontent/uploads/2013/05/DigitalUniverse2011.pdf&hl=pl&sa=X&ei=3u2AYvPG42Sy9YPmZGBY44&scisig=AAGBfm3-Wt70jz-_D6FkQcU1xu-9DBY2Q&oi=scholarrr (pobrano 11.06.2022).

- Reinsel, D., Gantz, J., & Rydning, J. (2018). *The Digitization of the World From Edge to Core*. IDC. <https://resources.moredirect.com/white-papers/idc-report-the-digitization-of-the-world-from-edge-to-core> (pobrano 11.06.2022).
- Schoenherr, T., & Speier-Pero, C. (2015). Data science, predictive analytics, and Big Data in supply chain management: Current state and future potential. *Journal of Business Logistics*, 36(1), 120–132. <https://doi.org/10.1111/jbl.12082>
- Wyrembek, M. (2022). *Wpływ technologii Big data na zarządzanie łańcuchem dostaw* [Niepublikowana praca magisterska]. Wyższa Szkoła Logistyki w Poznaniu.
- Zdrenka, W. (2017). The use and the future of Big Data analytics in supply chain management. *Research in Production and Logistics*, 7(2), 91–102. <https://doi.org/10.21008/j.2083-4950.2017.7.2.3>

Mgr Mateusz Wyrembek

Ukończył studia magisterskie w 2022 r. w Wyższej Szkole Logistyki w Poznaniu, na kierunku Logistyka, specjalność Projektowanie procesów logistycznych. Pierwsze doświadczenia zawodowe zdobywał w Grupie Raben, gdzie do dzisiaj pracuje w dziale reklamacji. Jego zainteresowania naukowe obejmują Big Data i uczenie maszynowe w zarządzaniu łańcuchem dostaw.

Mgr Mateusz Wyrembek

He completed his master's studies in 2022 at the Poznań School of Logistics, majoring in Logistics, specializing in Logistics Process Design. He gained his first professional experience in Raben Group, where he still works in the Claims Department. His research interests are Big Data and machine learning in supply chain management.

Material Economy and Logistics Journal

www.pwe.com.pl

Gospodarka Materiałowa i Logistyka

www.gmil.pl

ZNAJDZIESZ NAS TU

www.gmil.pl

tel. 795 155 583

ul. Podwale 17

00-252 Warszawa

