

9

Uczenie maszynowe jako budulec łańcuchów dostaw odpornych na opóźnienia – podejście zorientowane na interesariuszy

<https://doi.org/10.18559/978-83-8211-251-1/9>

 Mateusz Wyrembek

Uniwersytet Ekonomiczny w Poznaniu
mateusz.wyrembek@phd.ue.poznan.pl

Machine learning as a building block for resilient supply chains against delays—a stakeholder-centric approach

Abstract: The author focuses on enhancing the resilience of supply chains in the face of increasing globalisation and the complexity of business processes. The study investigates whether the data collected within the supply chain can be effectively utilised to build systems resilient to disruptions and delays using machine learning methods. Special emphasis is placed on understanding stakeholders' predictions of delivery delays, which is crucial for maintaining operational continuity and competitiveness. The chapter begins with a literature review on the application of machine learning in supply chain risk management, with a focus on predicting delays. The methodology section presents various machine learning techniques, such as decision trees, bagging, AdaBoost, and random forests. An experiment was conducted on an extensive dataset, using exploratory analysis to identify key features and build classifiers. The study focuses on analysing data from DataCo Global, attempting to predict delays and interpret the results for supply chain stakeholders. The experiment's results indicate that AdaBoost is the most effective algorithm for this task. This article highlights that machine learning offers promising opportunities in supply chain management but requires continuous development and adaptation to meet the dynamic challenges of this field.

Keywords: supply chain resilience, supply chain delays, machine learning.

Sugerowane cytowanie: Wyrembek, M. (2025). Uczenie maszynowe jako budulec łańcuchów dostaw odpornych na opóźnienia – podejście zorientowane na interesariuszy. W: M. Szymczak (red.), *Logistyka i zarządzanie łańcuchem dostaw w czasach turbulencji, zakłóceń i niestabilnej gospodarki* (s. 160–177). Wydawnictwo Uniwersytetu Ekonomicznego w Poznaniu. <https://doi.org/10.18559/978-83-8211-251-1/9>



Ta książka jest udostępniana na licencji Creative Commons Uznanie autorstwa-Użycie niekomercyjne-Bez utworów zależnych 4.0 Międzynarodowe

Wstęp

W dobie globalizacji i coraz większej złożoności procesów biznesowych zarządzanie łańcuchem dostaw stało się kluczowym elementem sukcesu przedsiębiorstw. Coraz częściej organizacje lokalizują swoje ośrodki produkcyjne z dala od rynków, aby optymalizować koszty (Anholcer i in., 2019). Z uwagi na to zjawisko dochodzi do wydłużania się łańcuchów dostaw, przez co ich odporność na różnorodne zakłócenia i niepewność rynkową jest niezbędną dla utrzymania konkurencyjności oraz zapewnienia stabilności działalności. W ostatnich latach takie technologie jak uczenie maszynowe¹ zyskały na znaczeniu jako narzędzia pozwalające na usprawnienie i zwiększenie odporności łańcuchów dostaw.

Współczesne badania w dziedzinie zarządzania łańcuchem dostaw koncentrują się na wykorzystaniu zaawansowanych technologii, zwłaszcza uczenia maszynowego, w celu zwiększenia efektywności i zmniejszenia ryzyka operacyjnego. W tym kontekście szczególnie istotne staje się zrozumienie i przewidywanie potencjalnych opóźnień w dostawach, co jest kluczowe dla utrzymania płynności i niezawodności całego łańcucha.

W ramach opracowania niniejszego rozdziału głównym celem jest zbadanie danych i zaprojektowanie wraz z implementacją klasyfikatorów do przewidywania opóźnień w łańcuchu dostaw przedsiębiorstwa DataCo Global. Badanie jako jedno z pierwszych podejmuje próbę nie tylko przewidywania opóźnień, ale również interpretacji i zrozumienia wyników przez interesariuszy łańcucha dostaw. W tym celu tematyka rozdziału skupia się na następujących kluczowych pytaniach badawczych:

- W jaki sposób różne metody uczenia maszynowego, takie jak klasyfikacja i regresja, są wykorzystywane do przewidywania opóźnień w łańcuchach dostaw?
- Jakie są główne wyzwania i ograniczenia w zastosowaniu algorytmów uczenia maszynowego do przewidywania opóźnień w łańcuchach dostaw?
- Jakie są potencjalne korzyści i ryzyka związane z wykorzystaniem uczenia maszynowego w łańcuchu dostaw przedsiębiorstwa DataCo Global do przewidywania opóźnień?

W pierwszej części rozdziału dokonano przeglądu literatury na temat zastosowania uczenia maszynowego w przewidywaniu opóźnień w łańcuchu dostaw. Następnie omówiono zastosowaną metodykę do przeprowadzenia eksperymentu. W ostatniej części omówiono poszczególne części projektu wraz z interpretacją wyników.

¹ W literaturze można spotkać wiele różnych definicji uczenia maszynowego. Przykładowo Wenzel i in. (2019) definiują je jako: „podobszar sztucznej inteligencji, który reprezentuje inny sposób programowania. Przykładowe dane zastępują sztywne reguły obliczeniowe programu. Z podanych przykładowych danych metody lub algorytmy uczenia wydobywają prawidłowości statystyczne i przedstawiają je w postaci modeli. Modele mogą reagować na nowe, nieznanne dane i klasyfikować je do kategorii lub dokonywać predykcji”.

9.1. Przegląd literatury

W ostatnich latach najbardziej znaną metodą w koncepcji zarządzania ryzykiem łańcucha dostaw jest zastosowanie nowej, cyfrowej technologii, takiej jak uczenie maszynowe.

Algorytmy uczenia maszynowego mają szeroki zakres zastosowań w zarządzaniu ryzykiem łańcucha dostaw, w tym wykrywanie oszustw finansowych (Constante-Nicolalde i in., 2020), przewidywanie ryzyka kredytowego (Xia i in., 2023), wyznaczanie najlepszych dostawców (Zheng i in., 2023) lub prognozowanie popytu (Carbonneau i in., 2008).

Jednym z nowatorskich i znaczących obszarów wykorzystania uczenia maszynowego w zarządzaniu ryzykiem łańcucha dostaw jest przewidywanie opóźnień. Na podstawie przeglądu literatury można wyodrębnić dwa główne podejścia do tego problemu: klasyfikację oraz regresję. W pierwszym przypadku badania (np. Baryannis i in., 2019; Brintrup i in., 2020; Cavalcante i in., 2019; Lolla i in., 2023; Sarbas i in. 2023; Wani i in., 2022) koncentrują się na przewidywaniu, czy dostawy są terminowe lub nieterminowe. Metody regresji, takie jak te zastosowane przez Steinberga i in. (2023), de Cos Jueza i in. (2010) oraz Biazon de Oliveirę i in. (2021), koncentrują się na dokładnym przewidywaniu czasu dostawy (*lead time*).

Wielu badaczy korzysta z publicznych zestawów danych, jak to widać w publikacjach Lolli i in. (2023), Wani i in. (2022) oraz Sarbasa i in. (2023), gdzie wykorzystywany jest zestaw danych z łańcucha dostaw przedsiębiorstwa DataCo Global. W pracach tych osiągane są wysokie wyniki predykcyjne zastosowanych algorytmów, wszystkie metryki w nich osiągają poziom powyżej 90%. Baryannis i in. (2019), Wyrembek (2023) oraz Brintrup i in. (2020) osiągnęli znaczącą wydajność predykcyjną, lecz napotkali problem tzw. kłutwy wielowymiarowości. Z tego też powodu, mimo teoretycznie wysokiej skuteczności, praktyczne zastosowanie tych rozwiązań w środowisku biznesowym mogłoby nie przynieść oczekiwanych rezultatów. W przypadku badania przeprowadzonego przez Cavalcante i in. (2019) jedynie miara dokładności została użyta do oceny ich modeli. Chociaż jest to jedna z najbardziej znanych miar, może dawać niezadowalające wyniki i ma ograniczoną użyteczność (Kozak i in., 2022). Wyrembek (2023) zastosował algorytm AdaBoost dostrajany przez algorytm optymalizacji mrowiskowej, dzięki czemu osiągnął dużą efektywność predykcyjną. Pomimo osiągnięcia wysokich wyników model działał na niedużym zestawie danych z małą liczbą dostaw nieterminowych, przez co najprawdopodobniej doszło do przeuczenia algorytmu.

Badania przeprowadzone przez Biazon De Oliveirę i in. (2021), Steinberga i in. (2023) oraz de Cos Jueza i in. (2010) koncentrują się na różnych problemach związanych z łańcuchem dostaw. Biazon De Oliveira i in. (2021) zaproponowali użycie algorytmów uczenia maszynowego do przewidywania czasów opóźnień dostaw

przez operatora logistycznego w łańcuchu dostaw leków. Z kolei Steinberg i in. (2023) skupili się na przewidywaniu czasu realizacji przez dostawców. Natomiast de Cos Juez i in. (2010) wykorzystali metodę SVM do przewidywania opóźnień dostaw komponentów metalowych w łańcuchu dostaw branży lotniczej, skupiając się na producencie. Wszystkie trzy badania mają jednak wspólne ograniczenie, polegające na analizowaniu tylko wybranego ogniwa, a nie całego łańcucha.

Badania przeprowadzone przez Viellechnera i Spinlera (2020) oraz Shaha i in. (2023) łączą oba podejścia. Badanie przeprowadzone przez Viellechnera i Spinlera (2020) miało na celu zwiększenie przejrzystości w zakresie opóźnień statków kontenerowych między Europą a Azją poprzez opracowanie modelu predykcyjnego. Sieć neuronowa dała najlepsze wyniki klasyfikacji, podczas gdy SVM wypadła najlepiej w modelowaniu regresji. Jednak ograniczeniem ich badania jest to, że skupili się na poziomie planowania strategicznego, aby wyciągnąć długoterminowe wnioski dotyczące operacji, zamiast skoncentrować się na codziennych krótkoterminowych dostosowaniach. Z drugiej strony Shah i in. (2023) zaproponowali wykorzystanie algorytmów uczenia maszynowego z zestawami danych utworzonymi z danych z sieci blockchain w celu usprawnienia operacji i zarządzania łańcuchem dostaw poprzez analizę liczby opóźnionych leków, długości opóźnienia i przewidywanie przyszłych opóźnień na podstawie danych dostarczonych dla określonego odcinka czasu. Jednak obecny stan badań Shaha i in. (2023) w tym obszarze jest wciąż na wczesnym etapie, proponując czysto teoretyczne rozwiązania, które nie zostały jeszcze wdrożone ani zastosowane w rzeczywistym studium przypadku.

Badania nad wykorzystaniem algorytmów uczenia maszynowego do przewidywania opóźnień w łańcuchach dostaw stoją przed wyzwaniami związanymi z obsługą wielowymiarowych danych i często koncentrują się na wybranym ogniwie łańcucha dostaw. Wskazać też należy, że niektóre prace mają charakter teoretyczny bez implementacji do środowiska biznesowego.

Zważywszy na luki badawcze zidentyfikowane w tym przeglądzie literatury, badanie stanowi unikatowe studium przypadku, które stosuje uczenie maszynowe do analizy predykcyjnej w zarządzaniu łańcuchem dostaw. Projekt koncentruje się na całym łańcuchu dostaw, przewidując, czy dostawa jest opóźniona, czy nie, przy użyciu zbioru danych DataCo Global. Przedstawione badanie stanowi jedną z pierwszych prób przewidywania opóźnień w łańcuchu dostaw przy jednoczesnej próbie interpretacji wyników dla jego interesariuszy.

9.2. Metodyka

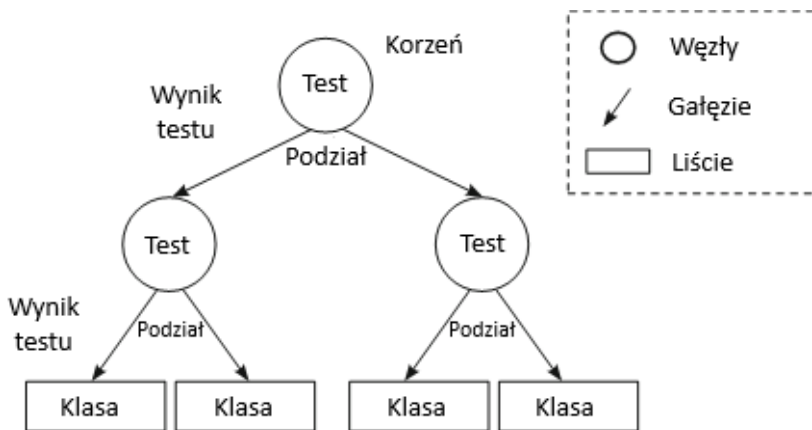
W części tej opisana zostanie przyjęta metodyka badania zgodna z rysunkiem 9.1.

9.2.1. Drzewo decyzyjne

Drzewa decyzyjne należą do popularnych metod klasyfikowania danych. Ich wykorzystanie jest istotne, zwłaszcza z powodu efektywności i prostoty procesu klasyfikacji obiektów z perspektywy złożoności obliczeniowej. Drzewo decyzyjne jest acyklicznym grafem skierowanym, który składa się z (Kozak, 2019):

- korzenia,
- wierzchołków określanych jako węzły,
- krawędzi, które są gałęziami,
- liści, czyli wierzchołków bez następców.

Drzewa decyzyjne należy określać jako model sukcesywny, który skutecznie i spójnie łączy serię podstawowych testów, w których cecha numeryczna jest porównywana z wartością progową w każdym teście (Jijo i Abdulazeez, 2023). W badaniu jest wykorzystywany algorytm z biblioteki *scikit-learn* znany jako `DecisionTreeClassifier()`, który wykorzystuje zoptymalizowaną wersję CART (drzewa klasyfikacji i regresji) do przewidywania zmiennej docelowej (Lolla i in., 2023). Przykładowe drzewo decyzyjne zostało zobrazowane na rysunku 9.2.



Rysunek 9.2. Przykładowe drzewo decyzyjne


Źródło: (Kozak, 2019).

9.2.2. Bagging

Bagging stanowi grupę klasyfikatorów zbudowanych na zasadzie agregacji bootstrapowej. Jest on często przedstawiany jako jeden z najwcześniejszych i zarazem najbardziej elementarny zestaw klasyfikatorów (Kozak, 2019).

Działanie algorytmu polega na agregacji, która przy przewidywaniu wyniku numerycznego wykorzystuje średnią z różnych wersji, a przy przewidywaniu klasy – głosowanie większościowe (Breiman, 1996). Każdy podzbiór danych (pseudopróbki) posiada tę samą liczbę elementów co oryginalny zestaw treningowy (próbka treningowa), a każda pseudopróbka jest generowana przez losowy wybór. Jeśli próbka treningowa zawiera n elementów, to każda pseudopróbka również będzie zawierać n elementów, przy czym każdy element z próbki treningowej jest wybierany z jednakowym prawdopodobieństwem wynoszącym $1/n$ (Kozak, 2019).

W badaniu wykorzystywany jest algorytm z biblioteki *scikit-learn* znany jako `BaggingClassifier()`, który wykorzystuje algorytm `DecisionTreeClassifier()` jako bazowy klasyfikator (Lolla i in., 2023). Przykład działania baggingu został przedstawiony na rysunku 9.3.



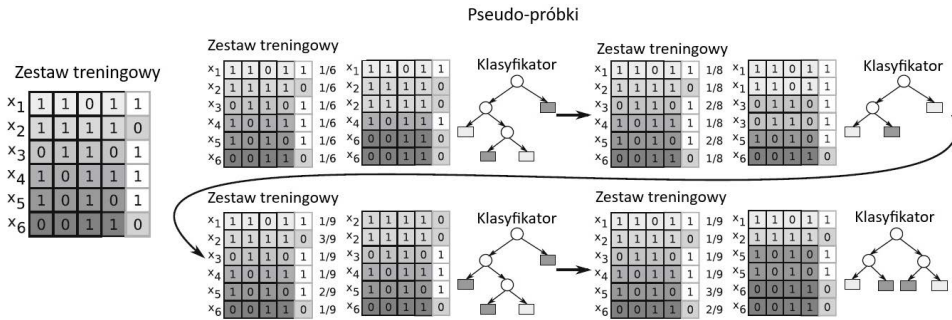
Rysunek 9.3. Schemat działania baggingu

Źródło: (Kozak, 2019).

9.2.3. Adaboost

AdaBoost został opracowany przez Freund'a i Schapire'a w 1995 roku (Chengsheng i in., 2017). Ten algorytm jest wyjątkową formą boostingu, która dostosowuje wagi obiektów w zestawie uczącym na podstawie błędów klasyfikacyjnych istniejących już klasyfikatorów w zestawie (Wyrembek, 2023).

W metodzie boostingu, podobnie jak w baggingu, tworzy się wiele słabych klasyfikatorów na podstawie specjalnie wygenerowanych pseudopróbek, a proces klasyfikacji opiera się na głosowaniu z wykorzystaniem wytworzonych klasyfikatorów. Pseudopróbki są tworzone poprzez ponowne losowanie, co oznacza, że z próbki treningowej o n elementach, dla każdej pseudopróbki losuje się zestaw n elementów. Początkowo pseudopróbka jest tworzona tak samo jak w baggingu, czyli każdy element ma takie samo prawdopodobieństwo wyboru $1/n$. W dalszych krokach



Rysunek 9.4. Schemat działania AdaBoost

Źródło: (Kozak, 2019).

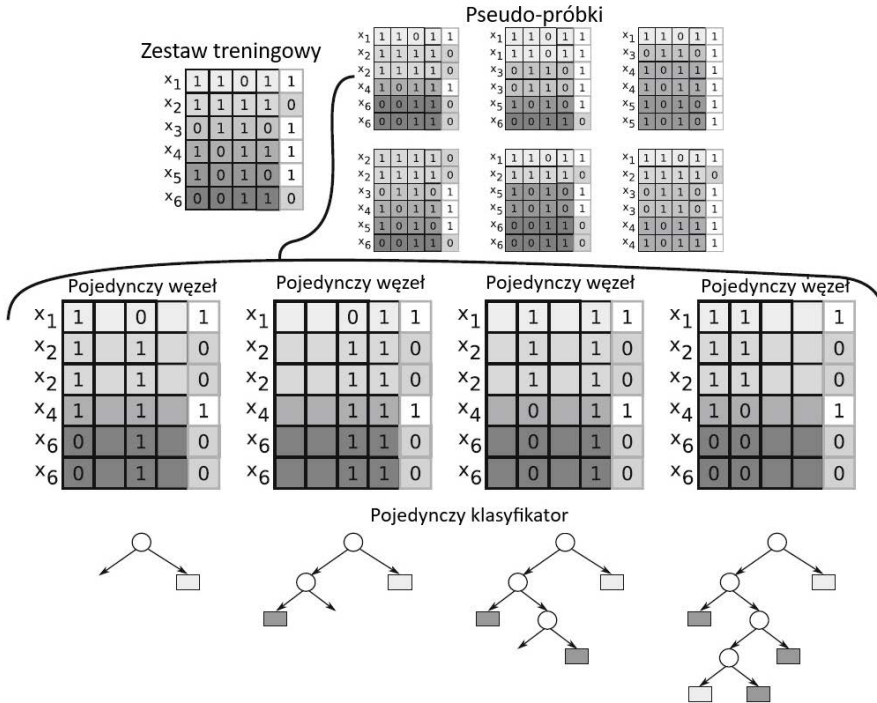
pseudopróbki są konstruowane w zależności od wyników klasyfikacji obiektów za pomocą drzewa decyzyjnego (lub innego klasyfikatora) utworzonego z pierwszej pseudopróbki (Kozak, 2019). Przykład działania AdaBoost został przedstawiony na rysunku 9.4.

9.2.4. Las losowy

Las losowy został również opracowany przez Breimana jako rozwinięcie baggingu (Breiman, 2001). Algorytm opiera się na analizie porównawczej z baggingiem i boostingiem. W lasach losowych jako podstawowy i jedyny klasyfikator wykorzystywane jest drzewo decyzyjne (Abdulla, 2023).

Lasy losowe inicjują swoje działanie przez stworzenie wielu pseudopróbek z zestawu treningowego. Każda pseudopróbka jest tworzona poprzez ponowne losowanie, co oznacza, że elementy są wybierane losowo z oryginalnego zestawu treningowego z równym prawdopodobieństwem. Proces ten generuje różne kombinacje danych, które mogą zawierać powtórzenia niektórych przypadków, zapewniając unikatowość każdej pseudopróbki. Następnie dla każdej pseudopróbki buduje się pojedyncze drzewo decyzyjne. W procesie tworzenia drzewa w każdym węźle jest wybierany podzbiór cech z całego zestawu, na którym dokonuje się podziału. To losowe wybieranie podzbioru cech pomaga w zapewnieniu różnorodności wewnątrz lasu i zwiększa jego odporność na przeuczenie. W końcowym etapie las losowy klasyfikuje nowe dane poprzez zastosowanie agregacji wyników z wszystkich drzew (Abdulla, 2023; Jafarzadeh, 2021; Kozak, 2019).

W przypadku zadań klasyfikacyjnych ostateczna decyzja jest wynikiem głosowania większościowego między drzewami – klasa, która otrzyma najwięcej głosów, zostaje wybrana jako przewidywanie lasu (Kozak, 2019). Przykład budowy lasu losowego został przedstawiony na rysunku 9.5.



Rysunek 9.5. Schemat budowy lasu losowego

Źródło: (Kozak, 2019).

9.2.5. GridSearchCV

GridSearchCV to metoda używana do znajdowania optymalnych hiperparametrów między innymi dla modeli klasyfikacyjnych (Radzi i in., 2021). Hiperparametry to ustalone konfiguracje, które nie zmieniają się automatycznie podczas procesu uczenia modelu, ale mają istotny wpływ na jego działanie i skuteczność (Bartz i in., 2023).

GridSearchCV przeszukuje siatkę możliwych hiperparametrów, systematycznie testując różne kombinacje w poszukiwaniu tej, która zapewnia najlepsze wyniki. Proces ten obejmuje walidację krzyżową, czyli podział danych na podzbiory, na których model jest trenowany i testowany, co pozwala ocenić jego efektywność (Bergstra i Bengio, 2012). Po przetestowaniu wszystkich kombinacji GridSearchCV wybiera najlepszy zestaw hiperparametrów, kierując się wybraną metryką oceny, taką jak między innymi dokładność klasyfikacji (Wang i in., 2022).

Metoda ta jest szczególnie wartościowa, gdyż pozwala na dokładne dostrojenie modelu, chociaż wymaga też dużej mocy obliczeniowej ze względu na konieczność wielokrotnego trenowania modelu.

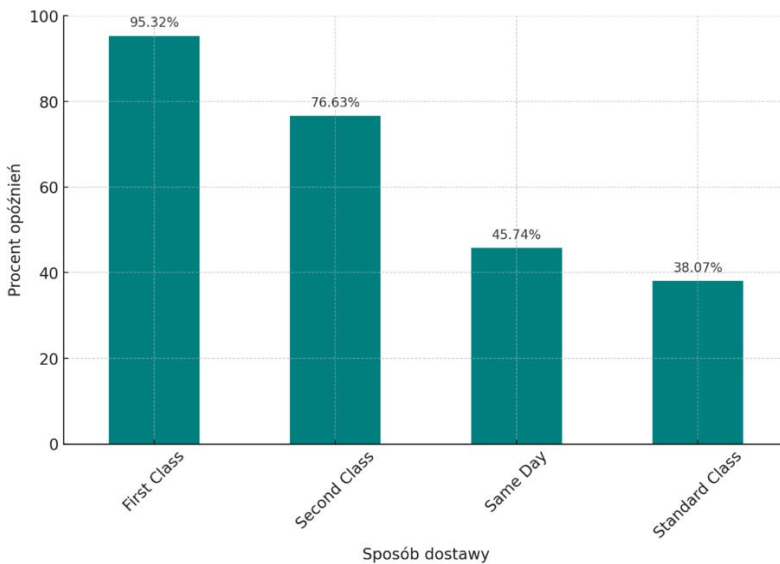
9.3. Eksperyment

Do przeprowadzenia niniejszego eksperymentu został użyty zestaw danych z łańcucha dostaw przedsiębiorstwa DataCo Global udostępniony przez Constante-Nicolalde i in. (2020). Informacje były zbierane w latach 2015–2018. Zestaw danych zawiera 180 519 rekordów w 53 kolumnach. Jako zmienną docelową wybrano `Late_delivery_risk`. Składa się ona z dwóch klas, wobec czego zachodzi tutaj problem klasyfikacji binarnej. Odpowiednie cechy zostaną wybrane za pomocą analizy eksploracyjnej. Eksperyment został wykonany na komputerze Macbook Air 2021, a modele wdrożone przy użyciu języka programowania python.

9.3.1. Eksploracyjna analiza danych

W uczeniu maszynowym analiza eksploracyjna to proces sprawdzania, oczyszczania, przekształcania i modelowania danych w celu odkrycia przydatnych informacji (Sarbas i in., 2023).

Pierwszym etapem było sprawdzenie, ile nieterminowych i terminowych dostaw jest w badanym zestawie danych. W latach 2015–2018 było 98 977 dostaw opóźnionych i 32 196 na czas. Na podstawie tej informacji należy stwierdzić, że zmienna docelowa nie jest mocno niezrównoważona. Ważne jest, aby zająć się tą kwestią na



Rysunek 9.6. Opóźnienie poszczególnych sposobów dostawy w ujęciu procentowym

Źródło: opracowanie własne.

tym etapie, ponieważ w przeciwnym razie może to prowadzić do nadmiernego lub niedostatecznego dopasowania modelu (Lolla i in., 2023). Istnieje kilka metod podejścia do tego problemu, jednakże w tym przypadku użyta zostanie metoda `RandomUnderSampler`, która usuwa losowo wybrane próbki z klasy większościowej w celu zrównoważenia liczby próbek między nimi (Bach i in., 2019).

Na podstawie analizowanego zbioru danych można stwierdzić, że jest to międzynarodowy łańcuch dostaw obejmujący między innymi Europę, Amerykę Północną i Południową, Afrykę i Azję. Przedsiębiorstwo oferuje cztery metody wysyłki do klienta końcowego, takie jak `First Class`, `Second Class`, `Same Day` oraz `Standard Class`. Opóźnienie w ujęciu procentowym poszczególnych sposobów dostawy zostały przedstawione na rysunku 9.6.

Na podstawie przeprowadzonej analizy wybrano następujące zmienne do zbudowania klasyfikatora: *Days for shipment scheduled* (liczba planowanych dni dostawy do odbiorcy), *Category Id* (identyfikator kategorii produktu), *Type* (typ płatności) oraz *Shipping Mode* (sposób dostawy). Proponowany klasyfikator w zapisie matematycznym wygląda następująco:

$$\text{Klasyfikator} = P(\text{Late_delivery_risk} | \text{Days for shipment scheduled}, \\ \text{Category Id}, \text{Type}, \text{Shipping Mode})$$

9.3.2. Budowa modeli i ocena jakości ich klasyfikacji

Po przeanalizowaniu danych i zdefiniowaniu cech modeli należy je zbudować. Do trenowania modeli użyto języka programowania python z wykorzystaniem między innymi bibliotek *scikit-learn*, *numpy* i *pandas*.

Pierwszym etapem było zastosowanie metody `GridSearchCV` do optymalizacji czterech różnych algorytmów uczenia maszynowego: `baggingu`, `AdaBoost`, drzewa decyzyjnego i lasu losowego. Każdy z tych algorytmów został dokładnie dostrojony przy użyciu specyficznych dla nich hiperparametrów, które przedstawiono w tabeli 9.1. Kluczowe parametry zostały ustalone na podstawie wstępnej analizy charakterystyki danych oraz specyfiki problemu opóźnień w łańcuchu dostaw.

W procesie doboru najlepszej konfiguracji przyjęto jako kryterium oceny dokładność predykcyjną modelu, co pozwoliło na bezpośrednie porównanie efektywności poszczególnych kombinacji hiperparametrów. Walidacja krzyżowa, przeprowadzona w ramach `GridSearchCV`, wykorzystwała pięciokrotny podział danych, co zwiększyło wiarygodność oceny modelu poprzez jego testowanie na różnorodnych podzbiorach. Takie podejście pozwoliło na systematyczne i rzetelne przeszukiwanie przestrzeni parametrów, co jest kluczowe w kontekście zastosowania algorytmów uczenia maszynowego do budowania łańcuchów dostaw odpornych na opóźnienia. Następnie na podstawie najlepszych hiperparametrów wytrenowano modele.

Tabela 9.1. Hiperparametry wybranych algorytmów

Algorytm	Hiperparametry	Opis
Adaboost	<i>n_estimators, learning_rate, algorithm, random_state</i>	liczba estymatorów, tempo uczenia, algorytm i stan losowości
Las losowy	<i>n_estimators, max_depth, min_samples_split, min_samples_leaf</i>	liczba drzew, maksymalna głębokość, minimalna liczba próbek do podziału i liścia
Drzewo decyzyjne	<i>criterion, max_depth, min_samples_split, min_samples_leaf</i>	kryterium podziału, maksymalna głębokość, minimalna liczba próbek do podziału i liścia
Bagging	<i>n_estimators, max_samples, max_features, bootstrap</i>	liczba estymatorów, maksymalna liczba próbek, maksymalna liczba cech, bootstrapping

Źródło: opracowanie własne.

W kontekście problemów klasyfikacji binarnej, takich jak ten rozważany, przypadki mogą być oznaczone jako pozytywne lub negatywne. Biorąc pod uwagę tę dychotomię, wyniki klasyfikacji można podzielić na cztery odrębne kategorie, które tworzą macierz pomyłek: prawdziwie pozytywne (TP), prawdziwie negatywne (TN), fałszywie pozytywne (FP) i fałszywie negatywne (FN). Zarówno TP, jak i TN reprezentują przypadki, w których klasyfikacja została przeprowadzona poprawnie. FP to fałszywy alarm, zwany także błędem typu I, a FN reprezentuje przypadki niesklasyfikowane, zwane także błędem typu II (Wyrembek, 2023). Innymi słowy można stwierdzić, że:

- TP – model prawidłowo przewidział wystąpienie opóźnienia,
- TN – model prawidłowo nie przewidział wystąpienia opóźnienia,
- FP – model błędnie przewidział wystąpienie opóźnienia,
- FN – model błędnie przewidział, że opóźnienie nie wystąpi.

Na podstawie macierzy pomyłek można obliczyć kilka miar wydajności dla modelu. obejmujących (Wyrembek, 2023):

- Dokładność mierzy odsetek poprawnie sklasyfikowanych przypadków wśród wszystkich instancji, w tym wyników prawdziwie pozytywnych (TP), prawdziwie negatywnych (TN), fałszywie pozytywnych (FP) i fałszywie negatywnych (FN).
- Precyzja odzwierciedla skuteczność modelu i wskazuje stosunek wyników prawdziwie pozytywnych (TP) do sumy wyników prawdziwie pozytywnych (TP) i fałszywie pozytywnych (FP).
- Pokrycie mierzy zdolność modelu do poprawnego identyfikowania pozytywnych instancji i jest definiowany jako stosunek wyników prawdziwie pozytywnych (TP) do sumy wyników prawdziwie pozytywnych (TP) i fałszywie negatywnych (FN).

- Wynik F1 jest miarą wydajności, która reprezentuje średnią harmoniczną precyzji i pokrycia, zapewniając zrównoważoną perspektywę wydajności modelu.
- Współczynnik korelacji Matthews (MCC) odzwierciedla skuteczność modelu w klasyfikacji binarnej. Uwzględnia on wyniki prawdziwie pozytywne (TP), prawdziwie negatywne (TN), fałszywie pozytywne (FP) i fałszywie negatywne (FN) i podaje wartość w zakresie od -1 do 1 . Jest on definiowany jako kowariancja między przewidywaną a rzeczywistą klasyfikacją binarną, podzielona przez iloczyn odchyłeń standardowych przewidywanej i rzeczywistej klasyfikacji.

W tabeli 9.2 przedstawiono wyniki oceny jakości klasyfikacji zbudowanych modeli. Najlepsze wyniki dla każdej oceny zostały pogrubione. Najlepszym klasyfikatorem jest AdaBoost.

Tabela 9.2. Wyniki oceny jakości klasyfikacji zbudowanych modeli

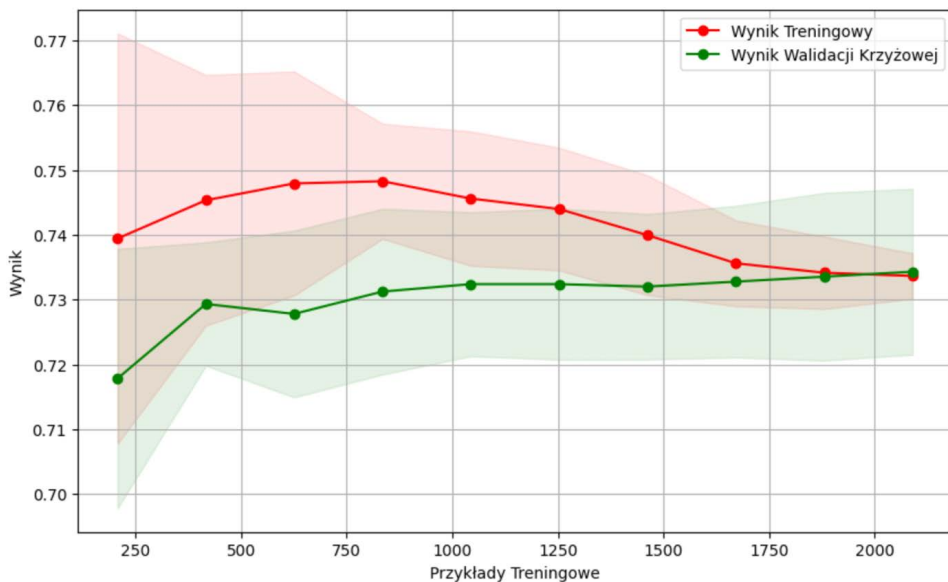
Klasyfikator	Dokładność	Precyzja	Pokrycie	Wynik F1	MCC	Czas treningu
AdaBoost	0,69	0,83	0,56	0,67	0,43	216,23 s
Las losowy	0,69	0,83	0,56	0,67	0,43	221,21 s
Drzewo decyzyjne	0,69	0,82	0,57	0,67	0,42	862,74 s
Bagging	0,69	0,80	0,59	0,68	0,42	3,85 s

Źródło: opracowanie własne.

9.3.3. Interpretacja

Jak już zauważono, najlepszym klasyfikatorem jest AdaBoost, co wynika z jego przewagi w większości metryk jakościowych. Dokładność modelu na poziomie 0,69, choć nie jest doskonała, wskazuje, że model ten skutecznie identyfikuje prawidłowe przypadki opóźnień w łańcuchu dostaw w prawie 70% przypadków. Jest to szczególnie istotne w kontekście zarządzania ryzykiem, gdzie każdy procent poprawy dokładności może przekładać się na znaczne oszczędności i optymalizację procesów. Precyzja klasyfikatora, na poziomie 0,83, sugeruje, że gdy przewiduje on wystąpienie opóźnienia, jest to predykcja bardzo wiarygodna. Dla menedżerów łańcuchów dostaw, którzy muszą szybko reagować na potencjalne zakłócenia, wysoka precyzja może oznaczać, że mogą oni podejmować środki zaradcze z większą pewnością co do ich potrzeby. Pokrycie wynoszące 0,56 może być obszarem do dalszej optymalizacji, ponieważ wskazuje na to, że model nie wykrywa wszystkich faktycznych przypadków opóźnień, co w rzeczywistości może prowadzić do niezauważenia niemal połowy potencjalnych problemów. Wynik F1 na poziomie 0,67, będący balansem między precyzją a pokryciem, potwierdza, że model ma umiarkowaną zdolność do jednoczesnego maksymalizowania obu tych metryk.

Współczynnik korelacji Matthews na poziomie 0,43, choć lepszy niż losowe przewidywanie, wskazuje na przestrzeń do poprawy. MCC jest często uznawany za bardziej wiarygodną miarę jakości klasyfikacji, szczególnie w przypadku niezbalansowanych klas, co jest typowe dla problemów związanych z łańcuchem dostaw, gdzie opóźnienia nie zdarzają się tak często jak terminowe dostawy. Czas treningu wynoszący 216,23 sekundy świadczy o relatywnie szybkiej zdolności do adaptacji modelu, co jest kluczowe w dynamicznie zmieniających się warunkach zarządzania łańcuchem dostaw, umożliwiając szybką aktualizację modelu w odpowiedzi na nowe dane lub warunki rynkowe.



Rysunek 9.7. Krzywe uczenia

Źródło: opracowanie własne.

Analizując krzywe uczenia (rysunek 9.7), obserwujemy, że zarówno wynik treningowy, jak i walidacji krzyżowej jest zbieżny przy większej liczbie przykładów treningowych, co wskazuje na stabilizację modelu. Brak znaczących różnic między tymi wynikami wskazuje na dobrą generalizację modelu. Wartości dokładności na poziomie od 0,73 do 0,75 oraz zbieżność krzywych sugerują, że model osiągnął punkt nasycenia, co implikuje, że dodanie większej ilości danych treningowych prawdopodobnie nie przyniesie znaczącej poprawy. W kontekście specyfiki zadania klasyfikacyjnego, naturalnej zmienności danych oraz bazowych wyników dla danego problemu przedstawiony klasyfikator wykazuje właściwe cechy zdolności predykcyjnej opóźnień w łańcuchu dostaw, zachowując równowagę między dopasowaniem do danych treningowych a generalizacją do nowych, niewidzianych przypadków.

Podsumowanie

Badanie to stanowi wkład w dziedzinę zarządzania łańcuchem dostaw, demonstrując możliwości zastosowania zaawansowanych technologii uczenia maszynowego do przewidywania opóźnień. Kluczowe pytania badawcze zostały rozważone, a odpowiedzi na nie znaleziono w kontekście konkretnego przypadku przedsiębiorstwa DataCo Global oraz przeglądu literatury:

Metody uczenia maszynowego w przewidywaniu opóźnień w łańcuchach dostaw: badanie potwierdziło efektywność różnych metod uczenia maszynowego, w tym drzew decyzyjnych, baggingu, AdaBoost oraz lasów losowych, w przewidywaniu opóźnień. Każda z tych metod ma swoje specyficzne zalety i ograniczenia, lecz AdaBoost wyróżniał się jako najbardziej efektywny w kontekście danego zadania.

Wyzwania i ograniczenia algorytmów uczenia maszynowego: ograniczenia te obejmują trudności związane z obsługą wielowymiarowych danych, ryzyko przeuczenia modeli oraz konieczność ciągłego dostosowywania algorytmów do zmieniających się warunków rynkowych. Ponadto istnieje wyzwanie w zakresie interpretacji wyników przez interesariuszy łańcucha dostaw, co zostało częściowo rozwiązane poprzez szczegółową analizę wyników i ich prezentację.

Korzyści i ryzyka związane z wykorzystaniem uczenia maszynowego: korzyścią jest możliwość lepszego przewidywania i zarządzania opóźnieniami, co przekłada się na optymalizację kosztów i poprawę efektywności operacyjnej.

Wnioski wyciągnięte z badania wskazują, że zastosowanie uczenia maszynowego w zarządzaniu łańcuchem dostaw może znacząco się przyczynić do lepszego przewidywania i zarządzania opóźnieniami. Jednakże sukces takich systemów zależy od ciągłej adaptacji do zmieniających się warunków oraz od skutecznej komunikacji wyników do interesariuszy. Mimo że najlepsze wyniki osiągnięto za pomocą klasyfikatora AdaBoost, dalsze badania mogą skupić się na optymalizacji innych algorytmów i eksploracji dodatkowych czynników wpływających na opóźnienia w łańcuchu dostaw.

W przyszłości można by rozważyć zastosowanie bardziej złożonych modeli uczenia maszynowego, takich jak głębokie sieci neuronowe, które mogą odkrywać bardziej subtelne wzorce w danych. Dodatkowo integracja z takimi technologiami jak blockchain może zapewnić jeszcze lepszą jakość danych i większą transparentność w całym łańcuchu dostaw.

Badanie to pokazuje, że choć uczenie maszynowe oferuje obiecujące możliwości w zarządzaniu łańcuchem dostaw, wymaga to ciągłego rozwoju, testowania i dostosowywania, aby sprostać dynamicznym i złożonym wyzwaniom w tej dziedzinie.

Bibliografia

- Abdulla, A., Baryannis, G. i Badi, I. (2023). An integrated machine learning and MARCOS method for supplier evaluation and selection. *Decision Analytics Journal*, 9, 100342.
- Anholcer, M., Hinc, T. i Kawa, A. (2019). Losses in transportation—importance and methods of handling. W: A. Kawa i A. Maryniak (red.), *SMART Supply Network* (s. 111–128). Springer. https://doi.org/10.1007/978-3-319-91668-2_6
- Bach, M., Werner, A. i Palt, M. (2019). The proposal of undersampling method for learning from imbalanced datasets. *Procedia Computer Science*, 159, 125–134. <https://doi.org/10.1016/j.procs.2019.09.167>
- Bartz, E., Bartz-Beielstein, T., Zaeferrer, M. i Mersmann, O. (red.). (2023). *Hyperparameter tuning for machine and deep learning with R: A practical guide*. Springer.
- Baryannis, G., Dani, S. i Antoniou, G. (2019). Predicting supply chain risks. Using machine learning: The trade-off between performance and interpretability. *Future Generation Computer Systems*, 101, 993–1004. <https://doi.org/10.1016/j.future.2019.07.059>
- Bergstra, J. i Bengio, Y. (2012). Random search for hyper-parameter optimization. *Journal of Machine Learning Research*, 13(10), 281–305. <https://www.jmlr.org/papers/volume13/bergstra12a/bergstra12a.pdf>
- Biazon de Oliviera, M., Zucchi, G., Lippi, M., Farias, C., Rosa da Silva, N. i Iori, M. (2021). *Lead time forecasting with machine learning techniques for a pharmaceutical supply chain. Paper presentation*. Proceedings of the 23rd International Conference on Enterprise Information Systems (ICEIS). <https://www.scitepress.org/Papers/2021/104344/104344.pdf>
- Breiman, L. (1996). Bagging predictors. *Machine Learning*, 24, 123–140. <https://doi.org/10.1007/BF00058655>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45, 5–32. <https://doi.org/10.1023/A:1010933404324>
- Brintrup, A., Pak, J., Ratiney, D., Pearce, T., Wichmann, P., Woodall, P. i McFarlane, D. (2022). Supply chain data analytics for predicting supplier disruptions: A case study in complex asset manufacturing. *International Journal of Production Research*, 58(11), 3330–3341. <https://doi.org/10.1080/00207543.2019.1685705>
- Cavalcante, I. M., Frazzon, E. M., Forcellini, F. A. i Ivanov, D. (2019). A supervised machine learning approach to data-driven simulation of resilient supplier selection in digital manufacturing. *International Journal of Information Management*, 49, 86–97. <https://doi.org/10.1016/j.ijinfomgt.2019.03.004>
- Carbonneau, R., Laframboise, K. i Vahidov, R. (2008). Application of machine learning techniques for supply chain demand forecasting. *European Journal of Operational Research*, 184(3), 1140–1154.
- Chengsheng, T., Huacheng, L. i Bing, X. (2017). *AdaBoost typical algorithm and its application research*. Proceedings of the 3rd International Conference on Mechanical, Electronic and Information Technology Engineering (ICMITE). <https://doi.org/10.1051/mateconf/201713900222>
- Constante-Nicolalde, F. V., Guerra-Terán, P. i Pérez-Medina, J. L. (2020). Fraud prediction in smart supply chains using machine learning techniques. W: M. Botto-Tobar, M. Zambrano Vizuete, P. Torres-Carrión, S. Montes León, G. Pizarro Vásquez i B. Durakovic

- (Eds.), *Applied technologies. ICAT 2019. Communications in computer and information science* (s. 145–159). Springer. https://doi.org/10.1007/978-3-030-42520-3_12
- de Cos Juez, F. J., García Nieto, P. J., Martínez Torres, J. i Taboada Castro, J. (2010). Analysis of lead times of metallic components in the aerospace industry through a supported vector machine model. *Mathematical and Computer Modelling*, 52(7–8), 1177–1184. <https://doi.org/10.1016/j.mcm.2010.03.017>
- Jafarzadeh, H., Mahdianpari, M., Gill, E., Mohammadimanesh, F. i Homayouni, S. (2021). Bagging and boosting ensemble classifiers for classification of multispectral, hyperspectral and PolSAR data: A comparative evaluation. *Remote Sensing*, 13(21), 4405. <https://doi.org/10.3390/rs13214405>
- Jijo, B. T. i Abdulazeez, A. M. (2021). Classification based on decision tree algorithm for machine learning. *Journal of Applied Science and Technology Trends*, 2(1), 20–28. <https://doi.org/10.38094/jastt20165>
- Kozak, J. (2019). *Decision tree and ensemble learning based on ant colony optimization*. Springer.
- Kozak, J., Probiez, B., Kania, K. i Juszczyk, P. (2022). Preference-driven classification measure. *Entropy*, 24(4), 531. <https://doi.org/10.3390/e24040531>
- Lolla, R., Harper, M., Lunn, J., Mustafina, J., Assi, J., Kim Loy, Ch. i Al-Jumeily, D. (2023). Machine Learning techniques for predicting risks of late delivery. W: Y. B. Wah, M. W. Berry, A. Mohamed i D. Al-Jumeily (red.), *Data science and emerging technologies. DaSET 2022. Lecture notes on data engineering and communications technologies* (vol. 165, s. 343–356). Springer.
- Radzi, S. F. M., Karim, M. K. A., Saripan, M. I., Rahman, M. A. A., Isa, I. N. C. i Ibahim, M. J. (2021). Hyperparameter tuning and pipeline optimization via grid search method and tree-based AutoML in breast cancer prediction. *Journal of Personalized Medicine*, 11(10), 978. <https://doi.org/10.3390/jpm11100978>
- Sarbas, P., Sanoob, K. S., Sravan, K., Hafiz, V. S., Thomas, A., Panicker, V. V. i Gopakumar, G. (2023). Development of predictive models for order delivery risk in a supply chain: A machine learning approach. W: X. Li, M. M. Rashidi, R. S. Lather i R. Raman (red.), *Emerging trends in mechanical and industrial engineering. Lecture notes in mechanical engineering* (s. 571–581). Springer. https://doi.org/10.1007/978-981-19-6945-4_43
- Shah, Y., Verma, Y., Sharma, U., Sampat, A. i Kulkarni, V. (2023). *Supply chain for safe & timely distribution of medicines using blockchain & machine learning*. Paper presented at the 2023 5th International Conference on Smart Systems and Inventive Technology (ICSSIT). Tirunelveli, India. <https://doi.org/10.1109/ICSSIT55814.2023.10061049>
- Steinberg, F., Burggräf, P., Wagner, J., Heinbach, B., Saßmannshausen, T. i Brintrup, A. (2023). A novel machine learning model for predicting late supplier deliveries of low-volume-highvariety products with application in a German machinery industry. *Supply Chain Analytics*, 1, 100003. <https://doi.org/10.1016/j.sca.2023.100003>
- Viellechner, A. i Spinler, S. (2020). *Novel data analytics meets conventional container shipping: Predicting delays by comparing various machine learning algorithms*. Paper presented at the 53rd Hawaii International Conference on System Sciences. <https://scholarspace.manoa.hawaii.edu/items/85219e6c-7ceb-4529-8f10-16b91e60a8eb>

- Wang, S., Lu, H., Khan, A., Hajati, F., Khushi, M. i Uddin, S. (2022). A machine learning software tool for multiclass classification. *Software Impacts*, 13, 100383. <https://www.sciencedirect.com/science/article/pii/S2665963822000847>
- Wani, D., Singh, R., Khanapuri, V. B. i Tiwari, M. K. (2022). Delay prediction to mitigate e-commerce supplier disruptions using voting mechanism. *IFAC-PapersOnLine*, 55(10), 731-736. <https://doi.org/10.1016/j.ifacol.2022.09.495>
- Wenzel, H., Smit, D. i Sardesai, S. (2019). A literature review on machine learning in supply chain management. *Artificial Intelligence and Digital Transformation in Supply Chain Management: Innovative Approaches for Supply Chains*, 27, 413-441.
- Wyrembek, M. (2023). The application of AdaBoost.M1 based on Ant Colony Optimization to classify the risk of delay in the pharmaceutical supply chain. *Logforum*, 19(2), 263-275. <https://doi.org/10.17270/J.LOG.2023.837>
- Xia, Y., Xu, T., Wei, M. X., Wei, Z. K. i Tang, L. J. (2023). Predicting chain's manufacturing SME credit risk in supply chain finance based on machine learning methods. *Sustainability*, 15(2), 1087.
- Zheng, G., Kong, L. i Brintrup, A. (2023). Federated machine learning for privacy preserving, collective supply chain risk prediction. *International Journal of Production Research*, 61(23), 8115-8132. <https://doi.org/10.1080/00207543.2022.2164628>