

Akademia WSB

Dąbrowa Górnicza, Kraków, Cieszyń, Żywiec, Olkusz, Gliwice, Tychy

mgr Marcin Mazgaj

**WYKORZYSTANIE TECHNOLOGII KOMUNIKACJI
ZDALNEJ I SZTUCZNEJ INTELIGENCJI
W ZARZĄDZANIU PROCESEM TARYFIKACJI
I KWOTACJI SKŁADEK
W TOWARZYSTWACH UBEZPIECZENIOWYCH**

Rozprawa doktorska napisana pod kierunkiem:
dr hab. inż. Marcin Hernes, profesor UEW

Dąbrowa Górnicza 2024

OŚWIADCZENIE PROMOTORA ROZPRAWY DOKTORSKIEJ

Oświadczam, że rozprawa doktorska pt. **Wykorzystanie technologii komunikacji zdalnej i sztucznej inteligencji w zarządzaniu procesem taryfikacji i kwotacji składek w towarzystwach ubezpieczeniowych** autorstwa mgr Marcina Mazgaja została przygotowana pod moim kierunkiem i stwierdzam, że spełnia ona warunki do przedstawienia jej w postępowaniu o nadanie stopnia naukowego.

Data Podpis promotora pracy

dr hab. inż. Marcin Hernes, profesor UEW

Dąbrowa Górnicza, dn. 26 września 2024 r.

OŚWIADCZENIE

Świadom odpowiedzialności prawnej oświadczam, że złożona rozprawa doktorska pt.:
Wykorzystanie technologii komunikacji zdalnej i sztucznej inteligencji w zarządzaniu procesem taryfikacji i kwotacji składek w towarzystwach ubezpieczeniowych została napisana przeze mnie samodzielnie.

Równocześnie oświadczam, że rozprawa doktorska nie narusza praw autorskich w rozumieniu ustawy z dnia 4 lutego 1994 roku o prawie autorskim i prawach pokrewnych (Dz. U. 1994, nr 24, poz. 83) oraz dóbr osobistych chronionych prawem cywilnym.

Ponadto rozprawa doktorska nie zawiera informacji i danych uzyskanych w sposób nielegalny i nie była wcześniej przedmiotem innych procedur urzędowych związanych z uzyskaniem dyplomów lub tytułów zawodowych uczelni wyższej.

Wyrażam również zgodę na udostępnianie rozprawy doktorskiej bez wynagrodzenia dla celów badawczych lub poznawczych Biblioteki Akademickiej Akademii WSB im. prof. J.Altkorna, z zastrzeżeniem, że udostępnianie to następować będzie wyłącznie na miejscu, w siedzibie Biblioteki.

.....

podpis doktoranta

Spis treści:

Podziękowanie	6
Wstęp	7
1. Problematyka procesu taryfikacji i kwotacji składki w towarzystwach ubezpieczeniowych w obszarze ubezpieczeń komunikacyjnych	18
1.1. Znaczenie i rola ryzyka towarzystw ubezpieczeniowych w ubezpieczeniach komunikacyjnych	18
1.2. Istota procesu taryfikacji i kwotacji składki ubezpieczeniowej	29
1.3. Dotychczasowe metody taryfikacji i kwotacji składki w ubezpieczeniach komunikacyjnych	31
1.4. Uzasadnienie potrzeby opracowania nowej metody taryfikacji i kwotacji składki w towarzystwach ubezpieczeniowych	36
2. Istota wykorzystania nowoczesnych technologii w towarzystwach ubezpieczeniowych	41
2.1. Nowe technologie w rozwoju ubezpieczeń komunikacyjnych towarzystw ubezpieczeniowych	41
2.2. Technologie Komunikacji Zdalnej	42
2.3. Technologie Sztucznej Inteligencji	46
3. Metodyka prowadzonych badań	60
3.1. Metodyczna koncepcja badań naukowych – triangulacja metod jakościowych i ilościowych	60
3.2. Metodyczna koncepcja badań empirycznych – metodyka Design Science Research Process	67
4. Nowa metoda taryfikacji i kwotacji składki w ubezpieczeniach komunikacyjnych w zakładach ubezpieczeń	70
4.1. Założenia metody taryfikacji i kwotacji składki	70
4.2. Określenie źródeł danych i sposobów ich pozyskania i przetwarzania z wykorzystaniem technologii komunikacji zdalnej	76
4.3. Konstrukcja metody taryfikacji i kwotacji składki	94
5. Projekt wdrożenia opracowanej metody	112
5.1. Prototyp systemu informatycznego taryfikacji i kwotacji składki	112
5.2. Implementacja nowej metody taryfikacji i kwotacji składki	116

5.3. Przeprowadzenie eksperymentów badawczych z wykorzystaniem prototypu systemu informatycznego	118
5.4. Przeprowadzenie badania ankietowego w wybranych towarzystwach ubezpieczeniowych	123
5.5. Ocena i wnioski w zakresie usprawnienia procesu taryfikacji i kwotacji składki	124
Podsumowanie	129
Literatura	132
Spis rysunków	142
Spis tabel	144
Załącznik 1	145
Załącznik 2	153
Załącznik 3	161
Załącznik 4	167
Streszczenie pracy	172

Podziękowania

Na wstępie chciałbym serdecznie podziękować mojemu promotorowi, dr hab. inż. Marcinowi Hernesowi, Profesorowi Uniwersytetu Ekonomicznego we Wrocławiu, za nieocenione wsparcie, cenne uwagi, inspirujące rozmowy oraz cierpliwość, które doprowadziły do powstania niniejszej dysertacji. Pańskie doświadczenie i zaangażowanie były dla mnie nieocenionym źródłem wiedzy i motywacji.

Wyrazy wdzięczności kieruję także do profesorów Akademii WSB: Prof. dr hab. Marka Lisińskiego, Prof. dr hab. Romana Niestoja, Prof. dr hab. Łukasza Sułkowskiego oraz dr hab. Katarzyny Szczepańskiej-Wolskiej, prof. AWSB, za przekazaną mi solidną dawkę wiedzy, wsparcie i wskazówki, które towarzyszyły mi w trakcie całego procesu badawczego.

Pragnę podziękować Panu Zbigniewowi Fidelusowi, właścicielowi Fideltronik Poland, za zainteresowanie tematem sztucznej inteligencji w ubezpieczeniach, wsparcie oraz otwartość na współpracę. Pańskie zaangażowanie przyczyniło się do realizacji badań, które stanowiły istotną część niniejszej pracy.

Słowa swojego podziękowania kieruję również do Pana Andrzeja Zdebskiego, którego nieoceniona pomoc umożliwiła realizację eksperymentu badawczego.

Na koniec, szczególne podziękowania kieruję do mojej żony Kasi, za jej nieustające wsparcie, cierpliwość i ogromne pokłady motywacji, które towarzyszyły mi na każdym etapie pracy nad rozprawą. Bez Twojej obecności, zrozumienia i codziennej motywacji, osiągnięcie tego celu byłoby znacznie trudniejsze. Dziękuję.

Wstęp

Uzasadnienie wyboru tematu pracy

Jednym z kluczowych procesów zarządzania ryzykiem ubezpieczeniowym towarzystw ubezpieczeniowych jest kalkulacja składki ubezpieczeniowej jako podstawy finansowania ryzyka ubezpieczeniowego¹. W aktualnym procesie zarządzania ryzykiem ubezpieczeniowym to rachunek prawdopodobieństwa oraz statystyka stanowią jej fundament². Metody te, pozwalają w sposób powszechny na ustalenie taryf i cen polis komunikacyjnych przez ubezpieczyciela. Wycenę składki dla klienta uzupełniają dane o sytuacji indywidualnego przypadku, na podstawie deklarowanego przez klienta stanu posiadania na dzień zawarcia umowy ubezpieczenia, uwzględniającego między innymi wiek, rodzaj i przeznaczenie pojazdu, wiek kierowcy i okres posiadania uprawnień do prowadzenia pojazdów mechanicznych oraz miejsce zamieszkania i użytkowania pojazdu³. Inne podejście charakterystyczne jest dla modeli a posteriori⁴ koncentrujących swoją uwagę na historii szkodowości kierowcy.

Dzisiaj pomimo dostępnych i zaawansowanych narzędzi aktuarialnych, umożliwiających uwzględnienie nawet rzędu 1000 (tysiąca) zmiennych będących w centrum zainteresowania i dostępności dla aktuariuszów, aktualny system wciąż funkcjonuje w realiach opartych o w/w modele, anachronicznej oferty ubezpieczeniowej i niskiego poziomu bezpieczeństwa rzeczywistego klienta, a w konsekwencji szczytu maksymalnego do osiągnięcia wyniku technicznego ubezpieczyciela w segmencie ubezpieczenia komunikacyjnego i spadającej marży towarzystw ubezpieczeniowych⁵.

Powodem tego stanu rzeczy jest brak fundamentalnej informacji o faktycznym położeniu przedmiotu ubezpieczenia i jego użycia w czasie rzeczywistym, bieżącej

¹ Ronka-Chmielowiec W. *Ryzyko ubezpieczeniowe – Współczesne wyzwania dla zakładów ubezpieczeń*. https://dSPACE.uni.lodz.pl/xmlui/bitstream/handle/11089/22346/%5b117%5d-130_Ronka-Chmielowiec_Ryzyko%20ubezpieczeniowe.pdf?sequence=1&isAllowed=y.

² Pojęcie procesu często definiowane jest w literaturze procesowych aspektów funkcjonowania organizacji. Jest to ciąg powiązanych ze sobą działań prowadzących do przekształcenia wszelkich nakładów w produkt procesu (R. L. Managenelli, M. M. Klein), zbiór działań wzajemnie powiązanych lub wzajemnie oddziałujących, które przekształcają wejścia w wyjścia (P. Grutkowski), ciąg określonych działań realizowanych w organizacji, będących kolejnymi etapami osiągania zdefiniowanego celu (A. Nosowski). Podobnie, definicje procesu jako łańcucha działań zawarte są w pracach: R. Mullera i P. Ruppera, M. Kunasza.

³ Szymańska A. „Wybrane metody szanowania stawek składki netto w ubezpieczeniach komunikacyjnych”, *Acta Universitatis Lodzensis Folia Oeconomica* 271, 2012.

⁴ Szymańska A. *Ibidem*, str. 193

⁵ Kuryłowicz Ł. „Usage-Based Insurance jako instrument przywracania równowagi na polski rynku ubezpieczeń komunikacyjnych” *Acta Universitatis Lodzensis* 1(333) 2018.

analizy ryzyka i możliwości natychmiastowej reakcji zawsze, gdy zachodzi potrzeba. To bardzo istotny element całego rynku ubezpieczeniowego, który w Polsce w 2022 roku, wyrażony był w kwocie składki przypisanej brutto w wysokości blisko 72,5 mld zł.

W ogólnej strukturze składek przypisanych brutto z działalności bezpośredniej, zakłady działu I odpowiadały za 29,8% składek, natomiast działu II za 70,2%. W dziale I dominującą rolę pod względem wartości zebranych składek brutto pełniła grupa "ubezpieczenia na życie", a kolejną pozycję zajmowała grupa "ubezpieczenia wypadkowe i chorobowe". Udziały tych dwóch grup w składkach przypisanych brutto działu I wyniosły odpowiednio 44,7% i 34,9%.

W dziale II największą część składek (51,3% wartości) stanowiły składki brutto zebrane z polis komunikacyjnych. W porównaniu z rokiem 2021 składki te wzrosły o 5,8%, osiągając wartość 26 051,4 mln zł. Udział ubezpieczeń casco pojazdów lądowych w składkach działu II wyniósł 21,7%⁶. To o czym musimy również pamiętać to fakt, że krajowy rynek ubezpieczeniowy jest jednocześnie jednym z najsłabiej rozwiniętych w Europie, w kontekście adekwatności wysokości składek, która jest odbiciem świadomości konsumentów.

Rewolucja cyfrowa początku obecnego tysiąclecia przyniosła powszechną komputeryzację, łatwy dostęp do korporacyjnych narzędzi bazodanowych, umożliwiających realizację szybkich i wielowarstwowych obliczeń⁷. Ukazała przy tym, że systemy informatyczne zakładów ubezpieczeń w procesie zarządzania ryzykiem komunikacyjnym osiągnęły szczyt możliwości wykorzystanych do prawidłowej kalkulacji składki ubezpieczeniowej. Jej prawidłowość oznacza, że towarzystwa ubezpieczeniowej kalkulują składkę w sposób umożliwiający wypłatę odszkodowań i pokrycie kosztów działalności przedsiębiorstwa.

Rosnące znaczenie technologii komunikacji zdalnej oraz sztucznej inteligencji, pozwala, zdaniem autora pracy na utworzenie inteligentnego środowiska ubezpieczeń, opartego o kompleksowe te technologie, zamieniając produkt ubezpieczeniowy w rzeczywistą usługę bezpieczeństwa dla Klienta oraz przemodelujące taryfę i strukturę składki ubezpieczeniowej w procesie zarządzania ryzykiem ubezpieczeniowym towarzystw ubezpieczeniowych. Wykorzystanie przywołanych technologii pozwoli

⁶ <https://stat.gov.pl/obszary-tematyczne/podmioty-gospodarcze-wyniki-finansowe/przedsiębiorstwa-finansowe/wyniki-finansowe-zakladow-ubezpieczen-w-2022-roku,7,39.html>

⁷ Accenture, PIU (2018). *Cyfryzacja Sektora Ubezpieczeń w Polsce*, Raport 2018. https://piu.org.pl/wp-content/uploads/2018/11/ACC_PIU_Raport-Cyfryzacja-Ubezpieczen-w-Polsce.pdf

również przyspieszyć proces budowy zakładów ubezpieczeń opartych na informacjach i wiedzy w ramach zintegrowanych systemów zarządzania zakładów ubezpieczeń, które uzyskają dzięki nim przewagę konkurencyjną⁸.

Stąd też tematyka badań realizowanych w niniejszej pracy wpisuje się głównie w subdyscyplinę zarządzania procesami nauk o zarządzaniu i jakości. Badania naukowe prowadzone w niniejszej rozprawie dotyczą bowiem zarządzania procesem taryfikacji i kwotacji w towarzystwach ubezpieczeniowych.⁹

W wyniku systematycznego przeglądu literatury przedmiotu¹⁰, zauważono **lukę naukową** polegającą na braku metod taryfikacji składki ubezpieczeniowej wykorzystujących technologię komunikacji zdalnej i sztuczną inteligencję w szerokim spektrum ubezpieczeń komunikacyjnych oraz zastosowania nowoczesnej matematyki aktuarialnej bazującej na analizie bieżących, pochodzących bezpośrednio z przedmiotu

⁸ Bytniewski A., Hernes M., *Wykorzystanie agentów kognitywnych w budowie zintegrowanego systemu informatycznego zarządzania*. Prace Naukowe/Uniwersytet Ekonomiczny w Katowicach 2013.

⁹ Co ciekawe, w literaturze przedmiotu brak jest opracowań dotyczących zarządzania procesami w zakładach ubezpieczeń. W publikacjach: M. Czubera, L. Gasiorkiewicza, W. Wojciechowskiego, A. Bitkowskiej, H. Nojszewskiego, P. Gołębia, M. Karmańskiej spotykamy się z opracowaniami dotyczącymi dekompozycji procesów działalności ubezpieczeniowej. W swoich rozważaniach na temat zarządzania procesami zakładów ubezpieczeń oparłem się na autorskim opracowaniu L. Gasiorkiewicza.

¹⁰ Malinowska K., *Ocena ryzyka w ubezpieczeniach a nowe technologie w kontekście zasad umowy ubezpieczenia*. Prawo Asekuracyjne 2/2019 (99). Podobnie Kurek, R. (2018). *InsurTechowe trendy na rynku ubezpieczeniowym*. Prace Naukowe UE we Wrocławiu 541: 138–146. Accenture (2018). *Machine Learning in Insurance* <https://www.accenture.com/acnmedia/pdf84/accenture-machine-learning-insurance.pdf>. Leciejewski M. „System kalkulacji składki w ubezpieczeniach komunikacyjnych (OP p.p.m.) typu Pay As You Drive”. Wiadomości Ubezpieczeniowe (4) 2017. Accenture (2020), Technology Vision for Insurance, AI and me Insurance, https://images.info.accenture.com/Web/ACCENTURE/%7Bce8af0f2-00d4-4cc6-a18b-b87e25e74e9d%7D_Accenture-Technology-Vision-for-Insurance-2020-Full-Report.pdf?elqcs=272&elqcsid=195.

McKinsey (2018), Digital insurance in 2018: Driving real impact with digital and analytics, December, <https://www.mckinsey.com/~media/mckinsey/industries/financial%20services/our%20insights/digital%20insurance%20in%202018%20driving%20real%20impact%20with%20digital%20and%20analytics/digital-insurance-in-2018.pdf>.

Porsche Bank, Smart Driver Porsche Versicherung, <https://www.porschebank.at/produkte/versicherung/smart-driver/>

Progressive (2021), Snapshot, <https://www.progressive.com/auto/discounts/snapshot/snapshot-details/>

Progressive (2021a), Snapshot FAQ, <https://www.progressive.com/auto/faq/>

KPMG (2021), Automobile Insurance in the Era of Autonomous Vehicles (n. d.), Insurance Journal Research, Retrieved August 16, <https://assets.kpmg/content/dam/kpmg/pdf/2015/12/Automobile-insurance-in-the-era-of-autonomous-vehicles-O-201506.pdf>.

EC (2021), The interoperable EU-wide eCall, <https://transport.ec.europa.eu/transport-themes/intelligent-transport-systems/road/action-plan-and-directive>.

Lamparelli N. (2016), On demand Insurance: Ultimately a Bust? <https://www.insurancethoughtleadership.com/emerging-technologies/demand-insurance-ultimately-bust>.

Bijak W., Dziel P., Garstka S., Hrycko K. (2015), Metody i modele statystyczne w wykrywaniu nieubezpieczonych posiadaczy pojazdów mechanicznych. „Roczniki Kolegium Analiz Ekonomicznych”, zeszyt 37, s. 199-227.

ubezpieczenia danych i ich korelacji z danymi z potencjalnie odległych źródeł oraz danych posiadanych przez zakłady ubezpieczeń.

Problemem naukowym podejmowanym w pracy jest usprawnienie procesu taryfikacji i kwotacji składki w towarzystwach ubezpieczeniowych z wykorzystaniem technologii komunikacji zdalnej i sztucznej inteligencji.

Pytania badawcze zostały sformułowane w następujący sposób:

- 1) W jaki sposób opracować metodę usprawniającą proces zarządzania taryfikacją i kwotacją składki, aby uwzględnić potrzeby klienta i ryzyko ubezpieczeniowe?
- 2) W jaki sposób wykorzystanie technologii komunikacji zdalnej i sztucznej inteligencji w budowie metody wpłynie na usprawnienie procesu taryfikacji i kwotacji składek?
- 3) W jaki sposób dokonać wdrożenia opracowanej metody w działalności towarzystw ubezpieczeniowych?

Oryginalne rozwiązanie problemu naukowego polega na opracowaniu metody taryfikacji i kwotacji składki ubezpieczeniowej uwzględniającej potrzeby klienta oraz ryzyko ubezpieczenia.

Podstawowe pojęcia wykorzystywane w rozprawie doktorskiej:

- **Towarzystwo ubezpieczeniowe/krajowy zakład ubezpieczeń – Krajowy zakład ubezpieczeń** – przedsiębiorcę w rozumieniu przepisów ustawy z dnia 6 marca 2018 r. – Prawo przedsiębiorców (Dz. U. z 2021 r. poz. 162 i 2105 oraz z 2022 r. poz. 24, 974 i 1570) z siedzibą na terytorium Rzeczypospolitej Polskiej, który uzyskał zezwolenie na wykonywanie działalności ubezpieczeniowej na terytorium Rzeczypospolitej Polskiej.
- **Taryfikacja składki** – ustalana indywidualnie przez towarzystwo ubezpieczeniowe stawka, która służy do prawidłowego wyliczenia składki, do opłacenia której zobowiązany jest ubezpieczony.
- **Kwotacja składki** – wycena ubezpieczenia.
- **Internet Rzeczy (IoT)** – Internet Rzeczy to sieć urządzeń fizycznych, pojazdów, budynków i innych przedmiotów wyposażonych w elektronikę, oprogramowanie, czujniki i sieci, które umożliwiają im zbieranie i wymianę danych¹¹.
- **Sztuczna inteligencja (AI)** – Sztuczna inteligencja (AI) odnosi się do teorii i rozwoju systemów komputerowych zdolnych do wykonywania zadań, które normalnie

¹¹ Atzori, L., Iera, A., & Morabito, G. (2010). The Internet of Things: A survey. Computer Networks, 54(15), 2787-2805.

wymagają ludzkiej inteligencji, takich jak rozpoznawanie mowy, podejmowanie decyzji, tłumaczenie języka czy uczenie się¹².

- **Telematyka** – Telematyka to technologia integrująca systemy telekomunikacyjne z systemami informatycznymi, umożliwiającą monitorowanie i analizowanie informacji, zwłaszcza w kontekście zarządzania flotą pojazdów i monitorowania zachowań kierowców¹³.
- **Uczenie maszynowe (ML)** – Uczenie maszynowe to poddziedzina sztucznej inteligencji, która umożliwia systemom komputerowym automatyczne uczenie się i doskonalenie na podstawie doświadczeń bez konieczności programowania przez człowieka¹⁴.
- **Algorytm wykrywania wypadków (Crash Detection)** – Algorytm wykrywania wypadków to technologia wykorzystująca dane z czujników w pojazdach w celu automatycznej identyfikacji zdarzeń drogowych takich jak kolizje czy wypadki, analizując siły działające na pojazd i inne zmienne¹⁵.
- **Big Data** – Big Data to zestaw technologii i metod analitycznych przeznaczonych do przetwarzania i analizowania ogromnych ilości danych, charakteryzujących się dużą objętością, zmiennością oraz różnorodnością¹⁶.
- **Dynamiczna taryfikacja** – Dynamiczna taryfikacja to metoda wyceny składek ubezpieczeniowych, która wykorzystuje aktualne, rzeczywiste dane o użytkowaniu pojazdów, takie jak prędkość, zachowania na drodze czy czas trwania podróży, zamiast tradycyjnych danych historycznych¹⁷.
- **Komunikacja zdalna** – różne standardy komunikacji umożliwiającej komunikację pomiędzy urządzeniami Internetu Rzeczy (IoT). Aktualnie wyróżnić można cztery główne grupy standardów komunikacyjnych dla IoT:
- **PAN (ang. Personal Area Network) i HAN (ang. Home Area Network)** – sieci krótkiego zasięgu, umożliwiające komunikację urządzeń osobistych (np. opaska

¹² Russell, S., & Norvig, P. (2016). Artificial Intelligence: A Modern Approach (3rd ed.). Pearson.

¹³ Gao, L. (2013). Telematics: Monitoring and management in transportation systems. *Journal of Transport Technologies*, 6(1), 78-90

¹⁴ Mitchell, T. (1997). *Machine Learning*. McGraw-Hill

¹⁵ Kaplan, D., & Zhu, Y. (2018). Real-time crash detection using machine learning. *Transportation Research Record*, 2672(20), 15-23.

¹⁶ Mayer-Schönberger, V., & Cukier, K. (2013). *Big Data: A Revolution That Will Transform How We Live, Work, and Think*. Houghton Mifflin Harcourt.

¹⁷ Baecke, P., & Bocca, L. (2017). The value of telematics data in car insurance. *Decision Support Systems*, 98, 69-79

mierząca jakość snu, monitor rytmu serca) i urządzeń wykorzystywanych w gospodarstwie domowym (np. automatyka domowa). Urządzenia pracujące w tych sieciach cechują się najniższym poborem mocy, a co za tym idzie najdłuższym czasem pracy na baterii.

- **LAN (ang. Local Area Network)** – sieć obejmująca większą powierzchnię. Urządzenia pracujące w tych sieciach to głównie różnego rodzaju sensory bezprzewodowe, które komunikują się z bramkami (ang. gateway) umożliwiającymi przesyłanie danych do sieci Internet.
- **WAN (ang. Wide Area Network)** – sieć rozległa pokrywająca duży obszar geograficzny. Do niedawna komunikacja bezprzewodowa w sieciach WAN oparta była jedynie o sieci GSM (2G, 3G, 4G), przez co urządzenia wymagały ciągłego zasilania. Ostatnie lata przyniosły pojawienie się nowej grupy technik komunikacji dedykowanych dla Internetu Rzeczy – LPWAN (ang. Low Power Wide Area Network). Wykorzystując te techniki komunikacji urządzenia mogą wysyłać niewielkie ilości danych na dalekie odległości korzystając jedynie z zasilania baterijnego. Techniki komunikacji LPWAN są stosowane przez wszelkiego rodzaju sensory, liczniki energii elektrycznej, trackery, a nawet większe urządzenia przesyłające dane diagnostyczne.
- **Zarządzanie procesem taryfikacji i kwotacji składki** – jeden z procesów poziomu operacyjnego zarządzania ryzykiem przez towarzystwo ubezpieczeniowe, który ma na celu zapewnienie odpowiedniego poziomu składki wystarczającego do pokrycia odszkodowań i kosztów.

Główny cel pracy i cele szczególne

Niniejsza rozprawa ma charakter metodyczno-projektowy. Projektowy charakter wynika z wymogów doktoratu wdrożeniowego, który jest realizowany w ramach niniejszej rozprawy doktorskiej.

Celem głównym pracy jest usprawnienie procesu taryfikacji i kwotacji składek ubezpieczeniowych przez zakłady ubezpieczeń z zastosowaniem technologii komunikacji zdalnej i sztucznej inteligencji.

Usprawnienie nastąpi poprzez opracowanie nowej metody taryfikacji i kwotacji, która skróci czas potrzebny do zakupu polisy z uwagi na fakt, że istota procesu dla poszukującego ochronę ubezpieczeniową sprowadzać się będzie do zainstalowania sensora np. na podszybiu samochodu i zeskanowaniu kodu QR z dowodu rejestracyjnego pojazdu. Wszystkie dane identyfikacyjne pojazdu zostaną automatycznie przesłane do systemu towarzystwa ubezpieczeniowego a w aplikacji telefonu kierowcy znajdzie numer rachunku potrzebny do opłacenia składki. System zatem w pierwszym etapie eliminuje konieczność uczestnictwa pośrednika ubezpieczeniowego bądź przedstawiciela towarzystwa ubezpieczeniowego.

W etapie drugim następuje zasadnicza analityka. Dane pochodzące wprost z użytkowanego pojazdu zasilają zdefiniowane na początku projektu algorytmy, których zasadniczym celem jest zapewnienie rentowności świadczonej ochrony ubezpieczeniowej. Element ten jest niezwykle trudny z uwagi na konieczność zestawienia danych pochodzących z pojazdu z danymi będącymi w posiadaniu towarzystwa ubezpieczeniowego, które są tradycyjną metodą stosowanych reguł kwotacji *a priori* i *a posteriori*. Trudność tego procesu dodatkowo utrudnia fakt, że większość posiadanych danych wymaga ich strukturyzacji do modelu wejściowego. Z pomocą przychodzi jednak sztuczna inteligencja, która w oparciu o ciągle uczący się algorytm (skutek ciągłego procesu pozyskiwania danych) eliminuje cały proces klasycznej pracy aktuariusza towarzystwa ubezpieczeniowego.

Podstawową funkcją nowej metody będzie utworzenie oferty ubezpieczeniowej blisko klienta zgodnie z koncepcją Klientocentryzmu¹⁸. W zakresie działalności towarzystwa ubezpieczeniowego będzie to wprowadzenie metody taryfikacji składki będącej realną oceną ryzyka każdego ubezpieczonego w wyniku której ubezpieczyciel

¹⁸ Definicja KE z dn. 22 listopada 2018 <https://www.eesc.europa.eu/en/agenda/our-events/events/industry-50>

realizuje swój podstawowy cel jakim jest zapewnienie realności i adekwatności ochrony ubezpieczeniowej.

Cele szczegółowe pracy zaprezentowano poniżej.

- **Cel teoretyczny** – rozszerzenie wiedzy w zakresie zarządzania procesem taryfikacji i kwotacji składki w ubezpieczeniach komunikacyjnych przez towarzystwa ubezpieczeniowe oraz metod wykorzystywanych w tym procesie.
- **Cel poznawczy** – rozpoznanie technologii komunikacji zdanej i sztucznej inteligencji, które można wykorzystać do opracowania nowej metody taryfikacji składki w ubezpieczeniach komunikacyjnych towarzystw ubezpieczeniowych.
- **Cel metodyczny** – opracowanie metody taryfikacji i kwotacji składki ubezpieczeniowej uwzględniającej potrzeby klienta oraz ryzyko ubezpieczenia.
- **Cel użyteczny** – opracowanie projektu wdrożenia metody taryfikacji i kwotacji składek ubezpieczeniowych w zakładach ubezpieczeniowych.

Hipoteza pracy

Opracowana nowa metoda umożliwi usprawnienie procesu taryfikacji i kwotacji składek ubezpieczeniowych co będzie skutkowało wzrostem poziomu dostosowania oferty ubezpieczeniowej do potrzeb klienta.

Koncepcja badawcza pracy

Metodyka badawcza

Metodyka badawcza całej pracy składa się z następujących kroków:

1. Analiza literatury przedmiotu.
2. Analiza procesu taryfikacji i kwotacji składek ubezpieczeniowych.
3. Analiza możliwości zastosowań komunikacji zdalnej, sztucznej inteligencji i innych technologii w procesie taryfikacji i kwotacji składek ubezpieczeniowych.
4. Opracowanie koncepcji metody taryfikacji i kwotacji składek.
5. Konstrukcja metody taryfikacji i kwotacji składek.
6. Opracowanie prototypu systemu posiadającego, między innymi, funkcje: geolokalizacji pojazdów, monitorowanie prędkości, rejestracja potencjalnie niebezpiecznych zdarzeń drogowych, w tym wykrywanie stłuczek i wypadków w trybie alarmowym przy użyciu transmisji danych za pomocą sieci GSM przez niezależny moduł komunikacyjny.

7. Implementacja opracowanej metody.
8. Przeprowadzenie eksperymentów badawczych. Eksperymenty badawcze mają na celu ewaluację opracowanej metody taryfikacji i kwotacji składek w środowisku prototypowym.
9. Przeprowadzenie pilotażu i studium przypadków.
10. Przeprowadzenie badania ankietowego w wybranych towarzystwach ubezpieczeniowych.
11. Analiza wyników badań.
12. Wnioski i podsumowanie.

Metodyka badań literaturowych

Przeprowadzony zostanie przegląd literatury. Przegląd literatury jest przeglądem systematycznym, bazy danych będą systematycznie przeszukiwane i uzupełniane w razie pojawienia się nowych artykułów dotyczących tematyki doktoratu.

Metodyka badań empirycznych

W badaniu zastosowana zostanie metodyka Design Science Research Process (DSRP). Metodyka ta obejmuje realizację prac badawczych jako etapów zależnych od procesu, odpowiedzialnych za realizację podstawowych zadań i dostarczanie podstawowych artefaktów pracy. Metodyka opiera się na pięciu podstawowych krokach. Pierwsza „*Świadomość problemu*” koncentruje się na przygotowaniu wstępnej propozycji nowego tematu badawczego, która zwykle wynika z analizy już dostępnych osiągnięć i wyników w pokrewnych dyscyplinach, a także w branży. Drugi, rozwój propozycji („*Sugestia*”), jest zgodny z pierwotną propozycją i jest kreatywnym krokiem mającym na celu zdefiniowanie nowych modeli, metod, funkcjonalności opartych na nowych konfiguracjach istniejących lub nowych elementów. Trzeci, rozwój wniosku („*Opracowanie*”), jest etapem, w którym wstępne badania są rozwijane i rozszerzane. Czwarty „*Ewaluacja*” to etap, w którym przygotowane artefakty są oceniane zgodnie z przyjętymi kryteriami. Piąty „*Podsumowanie*” może oznaczać koniec danego cyklu badawczego lub koniec całego przedsięwzięcia badawczego. Jak zaznaczono, każdy etap kończy się konkretnym wynikiem, który następnie stanowi podstawę i pozwala na następny etap procesu. Ponadto metodologia ta zakłada, że możliwy jest powrót do poprzednich etapów w ramach zaobserwowanych ograniczeń.

Metody badawcze wykorzystane w pracy:

- Analiza literatury przedmiotu,
- Analiza praktycznej dokumentacji,


- Obserwacje zjawisk,
- Studium przypadków,
- Eksperymenty badawcze,

Zostanie przeprowadzona symulacja zdarzenia drogowego w celu wykrycia wypadku drogowego, określenia jego kategorii oraz przygotowania algorytmu „car detection”.

- Metody ilościowe.

Zostanie przeprowadzone badanie z zakresu cyfryzacji działalności z udziałem towarzystw ubezpieczeniowych w postaci sesji dyskusyjnych zakończonych wypełnieniem ankiety opracowanej przez doktoranta pozwalająca na zbadanie zainteresowania implementacją nowej metody taryfikacji składki w ubezpieczeniach komunikacyjnych.

Hipoteza zostanie zweryfikowana poprzez przeprowadzenie pilotażowego wdrożenia do floty 500 pojazdów w oparciu o autorski *tracker* przygotowany we współpracy z Inssue Technologies w celu pozyskania danych związanych z poruszaniem się po drodze przez uczestników programu. Graficzną prezentację ekosystemu koncepcji weryfikacji hipotezy głównej przedstawia rysunek 1.



Rys. 1. Graficzna prezentacja ekosystemu koncepcji weryfikacji hipotezy głównej

Będzie to system bezobsługowy z punktu widzenia kierowcy i całkowicie niezależny w zakresie jego zasilania oraz komunikacji z chmurą co jest innowacyjnym rozwiązaniem. Dane uzyskane z sensorów zostaną porównane z zasobami danych posiadanych przez towarzystwa ubezpieczeniowe i będą przedmiotem analizy statystycznej pod kątem dostosowania oferty do potrzeb klienta.

Jednocześnie założono, iż udostępnienie właścicielowi oraz użytkownikowi pojazdu informacji analitycznych i użytkowych dotyczących konkretnego pojazdu oraz

przejrzysta komunikacja pozwoli na zapoznanie go z technologią¹⁹ i takie samo przełamanie impasu jakie obserwujemy w dziedzinie osobistych urządzeń elektronicznych, jak smartwatch czy smartfon.

¹⁹ Accenture (2018). *Machine Learning in Insurance* https://www.accenture.com/_acnmedia/pdf84/accenture-machine-learning-insurance.pdf. Problem utraty prywatności jest zdaniem doktoranta dużym ograniczeniem rozwoju nowoczesnych produktów ubezpieczeniowych. Podobnie Cieślak, B. (2017). *Zastosowania telematyki w ubezpieczeniach komunikacyjnych*, Roczniki Kolegium Analiz Ekonomicznych SGH 45: 79–91.

1. Problematyka procesu taryfikacji i kwotacji składki w towarzystwach ubezpieczeniowych w obszarze ubezpieczeń komunikacyjnych

1.1. Znaczenie i rola ryzyka towarzystw ubezpieczeniowych w ubezpieczeniach komunikacyjnych

Towarzystwa ubezpieczeniowe odgrywają kluczową rolę w polskiej gospodarce, zapewniając stabilność finansową oraz bezpieczeństwo majątkowe dla osób prywatnych i przedsiębiorstw. Dzięki nim możliwe jest łagodzenie skutków ryzyka, co w długoterminowej perspektywie wpływa na rozwój gospodarczy kraju. Wartość tego sektora można mierzyć zarówno bezpośrednim wpływem na PKB, jak i pośrednimi korzyściami wynikającymi z działalności ubezpieczeniowej²⁰.

Polski rynek ubezpieczeniowy charakteryzuje się dynamicznym wzrostem, co wynika z rosnącego zapotrzebowania na różnego rodzaju polisy. Według raportu Polskiej Izby Ubezpieczeń za 2022 rok, wartość składek przypisanych brutto wyniosła 66,7 mld zł, z czego 35,5 mld zł pochodziło z ubezpieczeń na życie, a 31,2 mld zł z ubezpieczeń majątkowych i pozostałych osobowych. Ubezpieczenia komunikacyjne stanowią istotną część tej struktury, z obowiązkowym ubezpieczeniem OC posiadaczy pojazdów mechanicznych generującym znaczną część przychodów.

Towarzystwa ubezpieczeniowe pełnią istotną rolę w gospodarce, realizując funkcje ochronne, prewencyjne i inwestycyjne. Zapewniają one ochronę finansową przed różnymi rodzajami ryzyka, takimi jak wypadki, choroby, śmierć czy straty majątkowe, co jest szczególnie ważne w kontekście ubezpieczeń komunikacyjnych. W 2022 roku składki z tytułu ubezpieczeń komunikacyjnych wyniosły 24,3 miliarda złotych, co stanowiło 36,4% całkowitego przypisu składki w sektorze ubezpieczeń majątkowych²¹.

Polski rynek ubezpieczeniowy jest największy w Europie Środkowo-Wschodniej i jednym z najbardziej dynamicznie rozwijających się w regionie. W porównaniu z innymi krajami europejskimi, Polska wyróżnia się zarówno wielkością rynku, jak i tempem wzrostu. Polski rynek ubezpieczeniowy przyciąga znaczące inwestycje zagraniczne i jest kluczowym elementem stabilności finansowej w regionie²².

²⁰ https://piu.org.pl/wp-content/uploads/2024/04/Ubezpieczenia_w_liczbach_2023.pdf

²¹ Polska Izba Ubezpieczeń (2022). Raport Roczny 2022. [online] Dostępne na: <https://piu.org.pl/wp-content/uploads/2022/12/Raport-roczny-2022.pdf>

²² tamże

Przed rynkiem ubezpieczeniowym w Polsce stoi wiele wyzwań, takich jak potrzeba adaptacji do zmian technologicznych, rosnące wymagania regulacyjne oraz zmieniające się oczekiwania klientów. Cyfryzacja i rozwój technologii, takich jak sztuczna inteligencja i telematyka, wpływają na sposób świadczenia usług ubezpieczeniowych oraz zarządzania ryzykiem. Jednym z głównych zagrożeń jest wzrastające ryzyko cyberataków oraz potrzeba ochrony danych osobowych klientów²³.

Rynek ubezpieczeniowy w Polsce jest bardzo mocno regulowany, co ma na celu zapewnienie stabilności i bezpieczeństwa finansowego. Do najważniejszych aktów prawnych regulujących działalność towarzystw ubezpieczeniowych należą:

- Ustawa o działalności ubezpieczeniowej i reasekuracyjnej z dnia 11 września 2015 r. (Dz.U. 2015 poz. 1844),
- Ustawa o dystrybucji ubezpieczeń z dnia 15 grudnia 2017 r. (Dz.U. 2017 poz. 2486), która wdraża dyrektywę IDD (Insurance Distribution Directive) mającą na celu ujednolicenie zasad dystrybucji ubezpieczeń w Unii Europejskiej,
- Ustawa o ubezpieczeniach obowiązkowych, Ubezpieczeniowym Funduszu Gwarancyjnym i Polskim Biurze Ubezpieczeń Komunikacyjnych z dnia 22 maja 2003 r. (Dz.U. 2003 nr 124 poz. 1152),
- Kodeks cywilny, który w art. 805-831 reguluje umowę ubezpieczenia.

Nadzór nad rynkiem ubezpieczeniowym sprawuje Komisja Nadzoru Finansowego (KNF), która monitoruje działalność zakładów ubezpieczeń, dbając o ich wypłacalność oraz adekwatność składek. KNF odgrywa kluczową rolę w zapewnieniu stabilności rynku ubezpieczeniowego i ochronie interesów konsumentów²⁴.

Kluczowym elementem funkcjonowania rynku ubezpieczeniowego jest zarządzanie ryzykiem. Zrozumienie istoty ryzyka, jego różnorodnych aspektów oraz sposobów jego oceny i taryfikacji jest niezbędne zarówno dla ubezpieczycieli, jak i dla ubezpieczonych²⁵.

Ryzyko jest nieodłącznym elementem naszego życia, zarówno na poziomie jednostkowym, jak i organizacyjnym. W codziennym języku ryzyko jest często postrzegane jako możliwość wystąpienia negatywnych zdarzeń lub sytuacji, które mogą mieć niepożądane konsekwencje. W kontekście naukowym i biznesowym, ryzyko

²³ Deloitte. (2023). 2023 Insurance Industry Outlook. Retrieved from Deloitte.

²⁴ Ubezpieczenia (2016). Red. Wanda Ronka-Chmielowiec - Warszawa: Wydawnictwo C.H. Beck, s. 89-104

²⁵ tamże

nabiera bardziej złożonego charakteru, obejmując szeroki zakres definicji, typologii i metod zarządzania²⁶.

Historia ryzyka jest historią naszego wysiłku, aby kontrolować niepewność i podejmować decyzje w obliczu nieprzewidywalnych przyszłych wydarzeń. Ryzyko towarzyszy wszystkim aspektom naszego życia – od prostych codziennych wyborów, przez decyzje biznesowe, aż po złożone operacje finansowe²⁷.

Postrzeganie ryzyka jest często intuicyjne i oparte na subiektywnych odczuciach oraz doświadczeniach. Ryzyko towarzyszy ludzkości od zarania dziejów²⁸. Ludzie zawsze musieli podejmować decyzje w obliczu niepewności, starając się przewidzieć i zminimalizować potencjalne zagrożenia. Przykłady ryzyka można znaleźć w wielu codziennych sytuacjach, takich jak prowadzenie pojazdu, podejmowanie decyzji finansowych czy uprawianie sportów ekstremalnych.

Jednym z kluczowych aspektów ryzyka jest jego subiektywność. Wiele osób może postrzegać te same sytuacje jako bardziej lub mniej ryzykowne w zależności od ich osobistych doświadczeń, przekonań i tolerancji na ryzyko. Na przykład, dla jednej osoby podróż samolotem może być źródłem dużego stresu i obaw, podczas gdy inna osoba może traktować ją jako rutynową i bezpieczną formę transportu.

Ta niepewność może dotyczyć zarówno zdarzeń naturalnych, jak i tych wywołanych przez człowieka. Przykłady ryzyka związanego z naturą obejmują ryzyko powodzi, trzęsień ziemi czy huraganów, podczas gdy ryzyko związane z działalnością człowieka może obejmować ryzyko wypadków drogowych, kradzieży czy upadłości przedsiębiorstwa.

Analiza ryzyka często obejmuje zarówno zagrożenia, jak i szanse. Na przykład, inwestycje finansowe są często postrzegane jako ryzykowne, ponieważ istnieje możliwość zarówno zysku, jak i straty. To dwojake postrzeganie ryzyka jako zagrożenia i szansy jest kluczowe w wielu decyzjach życiowych i biznesowych.

Ryzyko jest często silnie związane z emocjami. Strach przed ryzykiem może prowadzić do unikania pewnych działań, nawet jeśli potencjalne korzyści przeważają nad zagrożeniami. Z kolei odwaga w podejmowaniu ryzyka może prowadzić do znaczących

²⁶ Garbiec R. (2022). Ubezpieczenia w teorii i praktyce. Wydawnictwo Politechniki Częstochowskiej, s.7-11.

²⁷ Bernstein, P. L. (1996). *Against the Gods: The Remarkable Story of Risk*. Wiley

²⁸ tamże

osiągnięć i sukcesów. Wiele osób jest skłonnych podejmować ryzyko, jeśli wierzą, że korzyści przewyższają potencjalne straty.

W literaturze naukowej ryzyko jest definiowane i analizowane w kontekście różnych dziedzin, takich jak ekonomia, zarządzanie, psychologia oraz inne nauki społeczne i przyrodnicze. Nauka o ryzyku stara się nie tylko zrozumieć naturę ryzyka, ale także rozwijać metody jego pomiaru, analizy oraz zarządzania nim.

Ryzyko bywa definiowane jako możliwość wystąpienia niepożądanego zdarzenia, które może prowadzić do straty finansowej lub materialnej²⁹. W kontekście zarządzania, ryzyko jest często postrzegane jako niepewność dotycząca przyszłych zdarzeń, która może mieć wpływ na cele organizacji. Inni przedstawiciele literatury przedmiotu definiują ryzyko jako niepewność dotycząca przyszłych wyników, szczególnie w kontekście możliwości wystąpienia niepożądanych rezultatów³⁰.

W literaturze polskiej opisuje ryzyko jako niepewność związaną z wystąpieniem zdarzeń losowych, które mogą prowadzić do szkód finansowych dla jednostki lub organizacji³¹. W kontekście ubezpieczeń gospodarczych definiuje się ryzyko jako możliwość poniesienia strat wskutek zdarzeń losowych, które są przedmiotem umów ubezpieczeniowych³².

Ryzyko można podzielić na różne kategorie, w zależności od kontekstu i specyfiki analizowanej sytuacji. Przykładowe kategorie ryzyka obejmują ryzyko operacyjne, ryzyko finansowe, ryzyko strategiczne oraz ryzyko społeczne. Ryzyko operacyjne odnosi się do niepewności związanej z wewnętrznymi procesami, systemami i ludźmi w organizacji. Przykłady ryzyka operacyjnego obejmują błędy ludzkie, awarie systemów informatycznych oraz nieefektywne procesy operacyjne. Podkreśla się, że ryzyko operacyjne może prowadzić do bezpośrednich strat finansowych oraz innych negatywnych konsekwencji dla organizacji³³. Ryzyko operacyjne jest szczególnie istotne w branżach, gdzie precyzja i niezawodność są kluczowe, takich jak bankowość, produkcja i sektor technologiczny.

Ryzyko finansowe obejmuje niepewność dotyczącą przyszłych przepływów finansowych, wynikającą z wahań rynków finansowych, zmian stóp procentowych oraz

²⁹ Rejda, G. E. (2011). *Principles of Risk Management and Insurance*. Pearson, str. 32.

³⁰ Harrington, S. E., & Niehaus, G. R. (2004). *Risk Management and Insurance*. McGraw-Hill, str. 20

³¹ Ronka-Chmielowiec, W. (2009). *Ubezpieczenia. Ryzyko i zarządzanie ryzykiem*. Wydawnictwo C.H. Beck, str. 58

³² Monkiewicz, J. (2012). *Ubezpieczenia gospodarcze*. Poltext, str. 45.

³³ Rejda, G. E. (2011). *Principles of Risk Management and Insurance*. Pearson, str. 98.

zmienności kursów walut. Definiuje się ryzyko finansowe jako niepewność co do przyszłych wyników finansowych, która może wpływać na stabilność finansową organizacji ³⁴. Przykłady ryzyka finansowego obejmują ryzyko kredytowe, ryzyko rynkowe, ryzyko płynności oraz ryzyko walutowe. Ryzyko kredytowe dotyczy możliwości, że kontrahent nie wywiąże się ze swoich zobowiązań finansowych, co może prowadzić do strat dla organizacji. Ryzyko rynkowe odnosi się do niepewności związanej z wahaniami cen aktywów na rynkach finansowych. Ryzyko płynności dotyczy zdolności organizacji do zaspokajania swoich zobowiązań finansowych w krótkim okresie, a ryzyko walutowe związane jest ze zmianami kursów walutowych, które mogą wpływać na wartość transakcji międzynarodowych.

Ryzyko strategiczne związane jest z niepewnością dotyczącą decyzji strategicznych podejmowanych przez organizację. Może ono obejmować ryzyko związane z wejściem na nowe rynki, wprowadzeniem nowych produktów czy zmianą strategii biznesowej. W literaturze podkreśla się, że ryzyko strategiczne może mieć długoterminowy wpływ na sukces lub porażkę organizacji. Przykłady ryzyka strategicznego obejmują ryzyko konkurencyjne, ryzyko związane z technologią, ryzyko regulacyjne oraz ryzyko reputacyjne. Ryzyko konkurencyjne odnosi się do możliwości, że konkurenci wprowadzą na rynek produkty lub usługi, które będą bardziej atrakcyjne dla klientów. Ryzyko związane z technologią dotyczy niepewności związanej z rozwojem i wdrażaniem nowych technologii, które mogą wpłynąć na działalność organizacji. Ryzyko regulacyjne związane jest z możliwością wprowadzenia nowych przepisów prawnych, które mogą wpłynąć na działalność organizacji. Ryzyko reputacyjne odnosi się do możliwości, że negatywne wydarzenia lub informacje mogą zaszkodzić reputacji organizacji, co może prowadzić do utraty klientów i spadku wartości rynkowej.

Ryzyko społeczne odnosi się do niepewności wynikającej z interakcji społecznych oraz zmieniających się warunków społeczno-ekonomicznych. Przykłady ryzyka społecznego obejmują zmiany w preferencjach konsumentów, protesty społeczne oraz regulacje prawne. Ryzyko społeczne jest szczególnie istotne w kontekście zarządzania relacjami z interesariuszami, takimi jak klienci, pracownicy, społeczności lokalne oraz

³⁴ Harrington & Niehaus, 2004, s. 110.

organy regulacyjne. Zarządzanie ryzykiem społecznym wymaga zrozumienia dynamiki społecznej oraz proaktywnego podejścia do identyfikacji i zarządzania ryzykiem³⁵.

Ryzyko ubezpieczeniowe jest specyficzną kategorią ryzyka, która odnosi się do możliwości wystąpienia zdarzeń prowadzących do strat finansowych, które są przedmiotem umów ubezpieczeniowych. Ryzyko to odgrywa kluczową rolę w branży ubezpieczeniowej, wpływając na sposób kalkulacji składek, tworzenie rezerw oraz strategię zarządzania portfelem polis.

Ryzyko ubezpieczeniowe definiuje się jako niepewność dotyczącą wystąpienia zdarzeń losowych, które mogą prowadzić do szkód finansowych i są przedmiotem ochrony ubezpieczeniowej³⁶. Dodaje się również, że ryzyko w kontekście ubezpieczeń obejmuje ryzyko techniczne, ryzyko rynkowe oraz ryzyko operacyjne, które wpływają na wyniki finansowe zakładów ubezpieczeń³⁷.

W badaniach naukowych podkreśla się, że ryzyko ubezpieczeniowe wiąże się z prawdopodobieństwem wystąpienia szkody oraz wysokością tej szkody, co jest kluczowe przy ustalaniu wysokości składek ubezpieczeniowych³⁸. Wskazuje się, że ryzyko ubezpieczeniowe obejmuje nie tylko ryzyko losowe, ale także ryzyko systemowe, które może wpływać na całą branżę ubezpieczeniową³⁹.

Z perspektywy zagranicznej, zauważa, że ryzyko ubezpieczeniowe obejmuje prawne i regulacyjne aspekty związane z wystąpieniem szkód i zarządzaniem polisami ubezpieczeniowymi⁴⁰. Często również definiuje się ryzyko ubezpieczeniowe jako prawdopodobieństwo wystąpienia zdarzenia powodującego stratę oraz wielkość tej straty, co jest kluczowe dla ustalania składek ubezpieczeniowych⁴¹.

W obszarze ubezpieczeń komunikacyjnych ryzyko przybiera szczególnie istotne znaczenie, ponieważ jest bezpośrednio związane z potencjalnymi stratami finansowymi wynikającymi z wypadków, uszkodzeń pojazdów czy odpowiedzialności cywilnej kierowców. Ryzyko to obejmuje zarówno ryzyka związane z samymi pojazdami, jak i z

³⁵ Bracci, E., Tallaki, M., Gobbo, G., & Papi, L. (2021). "Risk management in the public sector: a structured literature review", *International Journal of Public Sector Management*, 34(2), 205-223.

³⁶ Kwiecień, Z. (2014). *Ryzyko i ubezpieczenia: Teoria i praktyka*. Wolters Kluwer Polska,

³⁷ Wąsiewicz, A. (2005). *Podstawy ubezpieczeń. Tom 1. Mechanizmy i funkcje*. Poltext, str. 56

³⁸ Kowalski, R. (2010). *Ryzyko i zarządzanie ryzykiem w ubezpieczeniach*. Wydawnictwo C.H. Beck, str. 45.

³⁹ Marcinkowska, E. (2013). *Systemowe ryzyko w sektorze ubezpieczeń*. Oficyna Ekonomiczna, str. 102.

⁴⁰ Abraham, K. S. (2010). *Insurance Law and Regulation*. Foundation Press, str. 65.

⁴¹ Pauly, M. V. (2007). *Handbook of Insurance*. Springer, str.

zachowaniem kierowców oraz warunkami drogowymi. Typologia ryzyka komunikacyjnego obejmuje następujące kategorie:

1) Ryzyko wypadków drogowych

Wypadki drogowe stanowią jedną z głównych przyczyn roszczeń ubezpieczeniowych. Ryzyko to jest związane z możliwością wystąpienia kolizji lub wypadków, które mogą prowadzić do szkód osobowych, materialnych oraz odpowiedzialności cywilnej⁴².

2) Ryzyko uszkodzeń pojazdów

Uszkodzenia pojazdów mogą wynikać zarówno z wypadków drogowych, jak i z innych przyczyn, takich jak wandalizm, kradzież czy działanie sił natury (np. grad, powódź). Ubezpieczenia autocasco (AC) obejmują tego rodzaju ryzyko, zapewniając ochronę finansową dla właścicieli pojazdów⁴³.

3) Ryzyko odpowiedzialności cywilnej kierowców

Odpowiedzialność cywilna kierowców dotyczy szkód wyrządzonych osobom trzecim w wyniku wypadków drogowych. Ubezpieczenia OC (odpowiedzialności cywilna posiadacza pojazdu mechanicznego za szkody w związku z ruchem pojazdu) są obowiązkowe w wielu krajach, w tym w Polsce, i mają na celu ochronę poszkodowanych przed finansowymi skutkami wypadków spowodowanych przez innych kierowców⁴⁴.

4) Ryzyko operacyjne

Ryzyko operacyjne w kontekście ubezpieczeń komunikacyjnych obejmuje błędy w zarządzaniu polisami, nieprawidłowe oceny ryzyka oraz inne wewnętrzne problemy towarzystw ubezpieczeniowych, które mogą wpływać na ich stabilność finansową⁴⁵.

5) Ryzyko regulacyjne

Zmieniające się przepisy prawne i regulacje dotyczące ubezpieczeń komunikacyjnych mogą wpływać na sposób funkcjonowania towarzystw ubezpieczeniowych. Przepisy te mogą obejmować zmiany w wymaganiach dotyczących minimalnych sum ubezpieczenia, procedur likwidacji szkód czy nowych obowiązków informacyjnych⁴⁶.

Skoro ryzyko jest nieodłącznym aspektem działalności ubezpieczeniowej, wpływającym na wszystkie aspekty operacyjne towarzystwa, od projektowania

⁴² Jędrzychowska, A., Poprawska, E., & Ronka-Chmielowiec, W. (2015). "Problem ryzyka zakładu ubezpieczeń pochodzącego z ubezpieczeń komunikacyjnych", *Studia Ekonomiczne. Zeszyty Naukowe Uniwersytetu Ekonomicznego w Katowicach* nr 242, str. 55

⁴³ Kwiecień, Z. (2014). *Ryzyko i ubezpieczenia: Teoria i praktyka*. Wolters Kluwer Polska, str.80.

⁴⁴ Wąsiewicz, (2005), s. 60.

⁴⁵ Marcinkowska, E. (2013). *Systemowe ryzyko w sektorze ubezpieczeń*. Oficyna Ekonomiczna, str. 105.

⁴⁶ Fuchs, D. (2004). "Pojęcie ryzyka i jego umiejscowienia w prawie ubezpieczeń gospodarczych", *Zeszyty Prawnicze UKSW*, 4(2), str. 17-31.

produktów po określanie warunków polis i wycenę składek, to skuteczne zarządzanie ryzykiem pozwala towarzystwom ubezpieczeniowym na unikanie nieoczekiwanych strat, zapewniając stabilność finansową i zdolność do wypłaty odszkodowania. Aby skutecznie zarządzać ryzykiem i minimalizować jego negatywne skutki, towarzystwa ubezpieczeniowe wdrażają kompleksowe systemy zarządzania ryzykiem. Te systemy nie tylko identyfikują i oceniają ryzyka, ale także implementują odpowiednie strategie kontrolne i monitorujące. Jest to niezbędne do zapewnienia stabilności finansowej oraz realizacji zobowiązań wobec klientów. Wg Kaczmarka, proces zarządzania ryzykiem można podzielić na kilka faz⁴⁷, co obrazuje tabela 1.

Tabela 1

Fazy procesu zarządzania ryzykiem

Faza Zarządzania Ryzykiem	Opis	Przykłady
Identyfikacja Ryzyka	Identyfikacja potencjalnych zagrożeń, które mogą wpłynąć na działalność organizacji. Analiza wszystkich możliwych źródeł ryzyka, zarówno wewnętrznych, jak i zewnętrznych.	– Analiza dokumentacji - przegląd raportów, protokołów i innych dokumentów w celu zidentyfikowania wcześniej zgłoszonych ryzyk oraz obszarów wymagających szczególnej uwagi. – Przegląd procesów - analiza wewnętrznych procesów operacyjnych, aby zidentyfikować potencjalne punkty awarii i nieefektywności. – Konsultacje z ekspertami - konsultacje z wewnętrznymi i zewnętrznymi ekspertami, aby zidentyfikować ryzyka specyficzne dla danej branży lub regionu.
Ocena Ryzyka	Analiza prawdopodobieństwa wystąpienia ryzyka oraz jego potencjalnych skutków. W tej fazie stosowane są modele matematyczne i statystyczne.	– Analiza scenariuszy - tworzenie różnych scenariuszy ryzyka i analizowanie ich potencjalnych skutków. – Modelowanie probabilistyczne - użycie modeli probabilistycznych, takich jak analiza Monte Carlo, do oszacowania prawdopodobieństwa wystąpienia różnych zdarzeń ryzykownych oraz ich skutków finansowych. – Analiza wpływu - ocena wpływu różnych ryzyk na działalność organizacji w celu priorytetyzacji ryzyk.
Kontrola Ryzyka	Implementacja strategii mających na celu minimalizację wpływu ryzyka. Może obejmować dywersyfikację portfela, wprowadzenie procedur operacyjnych czy zakup reasekuracji.	– Procedury bezpieczeństwa - stworzenie i egzekwowanie procedur minimalizujących ryzyko operacyjne. – Zakup reasekuracji - ubezpieczanie się przed ryzykiem poprzez zakup polis reasekuracyjnych. – Dywersyfikacja inwestycji - inwestowanie w różnorodne aktywa finansowe, aby zmniejszyć ryzyko związane z fluktuacjami rynkowymi.

⁴⁷ Kaczmarek, T. T. (2006). Zarządzanie ryzykiem. Poltext.

Monitorowanie i Raportowanie Ryzyka	Regularne monitorowanie ryzyka oraz ocena skuteczności strategii zarządzania ryzykiem. Raportowanie ryzyka zapewnia przejrzystość i zgodność z wymogami regulacyjnymi.	– Przeglądy ryzyka - okresowe przeglądy zidentyfikowanych ryzyk. – Raporty kwartalne - sporządzanie kwartalnych raportów dotyczących zarządzania ryzykiem. – Audyty wewnętrzne - przeprowadzanie audytów wewnętrznych w celu oceny skuteczności systemów zarządzania ryzykiem.
--	--	--

Źródło: Opracowanie własne

Pisząc o ryzyku ubezpieczeniowym, nie sposób pominąć underwriting ubezpieczeniowy, który jest procesem, w którym towarzystwo ubezpieczeniowe ocenia ryzyko związane np. z potencjalnym klientem i decyduje, czy zaakceptować to ryzyko, a jeśli tak, na jakich warunkach. Underwriting obejmuje analizę danych aplikacyjnych, historii ubezpieczeniowej oraz innych czynników ryzyka, które mogą wpływać na prawdopodobieństwo wystąpienia szkody⁴⁸.

W ubezpieczeniach komunikacyjnych underwriting to kluczowy element zarządzania ryzykiem, który pozwala na dokładną analizę i ocenę ryzyka związanego z pojazdami i kierowcami. Proces ten uwzględnia takie czynniki, jak historia jazdy, wiek i stan techniczny pojazdu, model oraz przebieg, które mają bezpośredni wpływ na prawdopodobieństwo wypadków lub awarii. Skuteczny underwriting pozwala na ustalenie adekwatnej składki, która odzwierciedla przyjęte ryzyko i zapewnia równowagę między atrakcyjnością cenową polisy a finansowym bezpieczeństwem towarzystwa⁴⁹.

Zarządzanie ryzykiem w towarzystwach ubezpieczeniowych jest złożonym procesem, który wymaga nie tylko odpowiednich narzędzi i metod, ale również zaangażowania kompetentnych osób pełniących funkcje kluczowe. Zgodnie z Dyrektywą Wypłacalność II, system zarządzania ryzykiem powinien obejmować kompletne procedury i polityki, które zapewniają efektywne identyfikowanie, ocenianie, monitorowanie, zarządzanie oraz raportowanie ryzyk, na jakie narażony jest zakład ubezpieczeń⁵⁰. Osoby pełniące funkcje kluczowe w zakładzie ubezpieczeń, takie jak menedżerowie ryzyka, aktuariusze czy audytorzy wewnętrzni, są odpowiedzialne za utrzymanie i doskonalenie systemu zarządzania ryzykiem. Ich rola jest krytyczna, gdyż od ich kompetencji, doświadczenia i rzetelności zależy skuteczność całego systemu⁵¹.

⁴⁸ Malinowska, K. (2019). Ocena ryzyka w ubezpieczeniach a nowe technologie w kontekście zasad umowy ubezpieczenia. Prawo Asekuracyjne nr 2.

⁴⁹ Bednarczyk, T. (2022). Ubezpieczenia wobec wyzwań współczesności. Poznań: Wydawnictwo Uniwersytetu Ekonomicznego w Poznaniu.

⁵⁰ <https://eur-lex.europa.eu/legal-content/PL/TXT/?uri=CELEX%3A32009L0138>

⁵¹ Mrozowska-Bartkiewicz, B. Wnęk, A (2017). Prawo Asekuracyjne nr 1

Aby w sposób pełny i zrozumiały przedstawić złożoności procesów zarządzania ryzykiem w ubezpieczeniach, podkreślając kluczowe role poszczególnych aspektów w tworzeniu efektywnego systemu zarządzania w towarzystwie ubezpieczeniowym, warto wspomnieć o zasadzie proporcjonalności, która ma kluczowe znaczenie w procesie underwritingu, szczególnie w kontekście ubezpieczeń komunikacyjnych⁵². Zasada proporcjonalności oznacza, że zakłady ubezpieczeniowe powinny stosować metody oceny ryzyka, które są adekwatne do rodzaju i skali działalności, a także złożoności przyjmowanych ryzyk. W praktyce, zasada ta pozwala na elastyczne dostosowywanie procedur underwritingowych, tak aby były one proporcjonalne do rzeczywistego ryzyka. Dzięki temu można unikać niepotrzebnie skomplikowanych i kosztownych procedur w przypadkach, gdy charakter ryzyka jest dobrze znany i przewidywalny, co jest często spotykane w ubezpieczeniach komunikacyjnych.

I właśnie w obszarze ubezpieczeń komunikacyjnych ryzyko przybiera szczególnie istotne znaczenie, ponieważ jest bezpośrednio związane z potencjalnymi stratami finansowymi wynikającymi z wypadków, uszkodzeń pojazdów czy odpowiedzialności cywilnej kierowców. Ryzyko to obejmuje zarówno ryzyka związane z samymi pojazdami, jak i z zachowaniem kierowców oraz warunkami drogowymi.

Ubezpieczenia komunikacyjne, zwłaszcza obowiązkowe ubezpieczenie odpowiedzialności cywilnej kierowców za szkody związane z ruchem pojazdów (ocppm) stanowią znaczącą część rynku ubezpieczeń majątkowych. Dominująca rola ubezpieczeń komunikacyjnych sprawia, że zarządzanie ryzykiem w tym obszarze jest kluczowe dla stabilności finansowej towarzystw ubezpieczeniowych.

Potencjalne straty finansowe związane z ryzykiem komunikacyjnym są znaczące. Wypadki drogowe mogą prowadzić do wysokich kosztów naprawy pojazdów, leczenia poszkodowanych oraz odszkodowań za szkody wyrządzone osobom trzecim. Towarzystwa ubezpieczeniowe muszą dysponować odpowiednimi rezerwami finansowymi, aby sprostać tym zobowiązaniom, co wpływa na ich płynność finansową oraz zdolność do wypłacania odszkodowań⁵³. Dodatkowo, próby ograniczenia kosztów naprawy przez ubezpieczycieli prowadzą do sytuacji, w której narzucane są ceny negocjowane z sieciami naprawczymi lub proponowane są kosztorysowe rozwiązania.

⁵² Ronka-Chmielowiec, W. (2017). Zarządzanie ryzykiem w ubezpieczeniach komunikacyjnych. Wydawnictwo Ubezpieczenia.

⁵³ Ronka-Chmielowiec, W. (2009). Ubezpieczenia. Ryzyko i zarządzanie ryzykiem. Poltext, str. 158.

Takie podejście, choć korzystne dla ubezpieczycieli, może być niekorzystne dla ubezpieczonych, którzy często otrzymują odszkodowania niepokrywające pełnych kosztów naprawy pojazdów⁵⁴. To może prowadzić do sytuacji, gdzie właściciele pojazdów muszą pokrywać dodatkowe koszty z własnej kieszeni lub wybierać tańsze, mniej skuteczne naprawy, co może obniżyć wartość i bezpieczeństwo pojazdu.

Ocena ryzyka jest kluczowym elementem procesu ustalania składek ubezpieczeniowych. Dokładne oszacowanie ryzyka pozwala na ustalenie adekwatnych składek, które odzwierciedlają rzeczywiste zagrożenia związane z eksploatacją pojazdów. Niedooszacowanie ryzyka może prowadzić do strat finansowych dla towarzystw ubezpieczeniowych, podczas gdy przeszacowanie może skutkować utratą klientów na rzecz konkurencyjnych firm oferujących niższe składki⁵⁵.

Efektywne zarządzanie ryzykiem komunikacyjnym obejmuje nie tylko ocenę ryzyka, ale także działania prewencyjne mające na celu zmniejszenie liczby i skutków wypadków drogowych. Towarzystwa ubezpieczeniowe inwestują w kampanie edukacyjne, promowanie bezpiecznej jazdy oraz wdrażanie nowoczesnych technologii, takich jak telematyka, które umożliwiają monitorowanie zachowań kierowców i identyfikowanie ryzykownych zachowań⁵⁶. Działania prewencyjne są kluczowe dla redukcji szkód i zwiększenia bezpieczeństwa na drogach⁵⁷.

W USA, programy prewencyjne często obejmują współpracę z instytucjami rządowymi i organizacjami non-profit w celu promowania bezpieczeństwa drogowego. Na przykład, kampanie takie jak „Click It or Ticket” skutecznie zwiększyły używanie pasów bezpieczeństwa, co znacząco zmniejszyło liczbę ofiar śmiertelnych w wypadkach drogowych⁵⁸.

Warto również zaakcentować wpływ regulacji prawnych na obszar zarządzania ryzykiem komunikacyjnym. Przepisy dotyczące obowiązkowego ubezpieczenia (ocppm), minimalnych sum ubezpieczenia oraz procedur likwidacji szkód mają na celu ochronę konsumentów oraz mają za zadanie zapewnienie stabilności rynku ubezpieczeniowego. Komisja Nadzoru Finansowego (KNF) pełni kluczową rolę w

⁵⁴ KNF. (2022). Rekomendacje dotyczące likwidacji szkód z ubezpieczeń komunikacyjnych. Komisja Nadzoru Finansowego.

⁵⁵ Rejda, G. E. (2011), s. 120.

⁵⁶ Kwiecień Z. (2014), s. 80.

⁵⁷ Vaughan, E. J. (1997). Risk Management. Wiley, str. 45.

⁵⁸ Hubbard, D. W. (2009). The Failure of Risk Management: Why It's Broken and How to Fix It. John Wiley & Sons, str. 110.

monitorowaniu działalności zakładów ubezpieczeń, dbając o ich wypłacalność oraz adekwatność składek.

Ewolucja orzecznictwa dotyczącego wypłat odszkodowań i zadośćuczynień dodatkowo wpływa na praktyki ubezpieczycieli. Zmieniające się przepisy i orzeczenia sądów wprowadzają nowe wyzwania, wymagając od towarzystw ubezpieczeniowych ciągłego dostosowywania swoich strategii zarządzania ryzykiem. Na przykład, wyroki nakazujące wyższe odszkodowania za szkody osobowe mogą prowadzić do wzrostu kosztów dla ubezpieczycieli, co z kolei wpływa na kalkulację składek i rezerw finansowych⁵⁹.

Przed towarzystwami ubezpieczeniowymi stoi wiele wyzwań związanych z zarządzaniem ryzykiem komunikacyjnym. Zmieniające się warunki drogowe, rozwój technologii oraz rosnące wymagania konsumentów wymuszają ciągłe dostosowywanie strategii zarządzania ryzykiem. W przyszłości, rozwój autonomicznych pojazdów oraz dalsza cyfryzacja usług ubezpieczeniowych mogą znacząco wpłynąć na sposób oceny i zarządzania ryzykiem komunikacyjnym⁶⁰.

1.2. Istota procesu taryfikacji i kwotacji składki ubezpieczeniowej

Taryfikacja składki ubezpieczeniowej to proces ustalania ceny polisy na podstawie oceny ryzyka związanego z potencjalnym zdarzeniem ubezpieczeniowym⁶¹. W ramach tego procesu, ubezpieczyciel analizuje różne czynniki ryzyka, które mogą wpływać na prawdopodobieństwo wystąpienia szkody i jej potencjalną wysokość. Czynniki te mogą obejmować wiek, historię ubezpieczeniową, stan zdrowia (w przypadku ubezpieczeń na życie), lokalizację, typ i wartość przedmiotu ubezpieczenia (np. pojazd, nieruchomość). Taryfikacja jest kluczowym elementem zarządzania ryzykiem, ponieważ pozwala ubezpieczycielowi na ustalenie odpowiednich stawek premii, które odzwierciedlają przejmowane ryzyko, zabezpieczając równocześnie interesy finansowe towarzystwa ubezpieczeniowego.

Kwotacja składki ubezpieczeniowej to proces, w którym ubezpieczyciel przedstawia potencjalnemu klientowi ofertę cenową za ubezpieczenie. Jest to konkretna propozycja

⁵⁹ KNF (2022)

⁶⁰ Jędrzychowska (2015) str. 55.

⁶¹ Ronka-Chmielowiec, (2017).

oparta na wcześniej przeprowadzonej taryfikacji, która uwzględnia wszystkie relewantne informacje o kliencie i jego potrzebach ubezpieczeniowych. Kwotacja składki jest finalnym etapem w procesie sprzedaży polisy i często uwzględnia również możliwe opcje dostosowania ubezpieczenia do indywidualnych potrzeb klienta, takie jak wybór zakresu ochrony czy franszyzy (udziału własnego w szkodzie)⁶².

Główna różnica między taryfikacją a kwotacją polega na tym, że taryfikacja jest procesem wewnętrznym, którego celem jest ustalenie, ile powinna kosztować polisa na podstawie oceny ryzyka, podczas gdy kwotacja jest zewnętrznym procesem komunikacji z klientem, przedstawiającym wynik taryfikacji w formie konkretnej oferty finansowej. Taryfikacja opiera się na analizie i ocenie ryzyka, natomiast kwotacja to bezpośrednia interakcja z klientem, mająca na celu sprzedaż produktu ubezpieczeniowego w oparciu o wyniki taryfikacji.

Pierwszym krokiem w procesie taryfikacji jest zbieranie danych o potencjalnym ubezpieczonym i obiekcie ubezpieczenia. Dane te mogą obejmować wiek i doświadczenie kierowcy, historię jazdy, informacje o pojazdach (marka, model, rok produkcji, przebieg), a także statystyki dotyczące wypadków w regionie, w którym kierowca mieszka i jeździ. Następnie, na podstawie zebranych danych, stosuje się modele aktuarialne do oceny ryzyka. Te modele analizują prawdopodobieństwo wystąpienia szkody i jej potencjalną wartość. Ryzyko jest oceniane na podstawie historycznych danych o szkodowości i statystyk, a także za pomocą technik predykcyjnych takich jak regresja, drzewa decyzyjne czy zaawansowane techniki uczenia maszynowego⁶³.

Wyznaczona składka bazowa stanowi punkt wyjściowy dla dalszych kalkulacji. Jest to kwota, która pokrywa przewidywane koszty szkód, koszty operacyjne ubezpieczyciela oraz zapewnia odpowiedni zysk. W literaturze aktuarialnej składka bazowa jest często wyznaczana przy użyciu modeli statystycznych i matematycznych, które uwzględniają historyczne dane szkodowości oraz demograficzne i behawioralne profile ryzyka⁶⁴.

W kolejnym etapie do składki bazowej dodawane są zwyżki lub naliczane są zniżki, w zależności od dodatkowych czynników ryzyka lub historii ubezpieczonego. Przykłady takich modyfikacji mogą obejmować zniżki za bezszkodową jazdę, zwyżki za częste szkody czy dostosowania związane z użytkowaniem pojazdu w celach komercyjnych.

⁶² Ortyński, K. (2003). Zarządzanie selekcją i oceną ryzyka ubezpieczeniowego (underwriting). W J. Monkiewicz (Red.), Podstawy ubezpieczeń (t. 3 – Przedsiębiorstwo, s. 147-151). Warszawa: Poltext

⁶³ Ronka-Chmielowiec, (2017).

⁶⁴ Lemaire, J. (1995). Bonus-malus systems in automobile insurance. Kluwer Academic Publishers.

Ostateczna składka, którą klient musi zapłacić, jest kalkulowana po uwzględnieniu wszystkich zniżek i zwyżek. Jest to kwota, którą klient widzi na swojej polisie ubezpieczeniowej. Finalna składka, już po uwzględnieniu wszystkich zniżek i zwyżek, jest przedstawiana klientowi. Jest to cena, którą klient musi zapłacić, aby uzyskać pożądane pokrycie ubezpieczeniowe. Ubezpieczyciel w tym momencie zapewnia pełną transparentność kosztów, aby klient mógł świadomie podjąć decyzję o zakupie polisy. Jest to konsekwencja regulacji europejskich, takich jak Dyrektywa IDD (Insurance Distribution Directive) oraz krajowych, takich jak Ustawa o dystrybucji ubezpieczeń oraz dobre praktyki w zakresie ubezpieczeń⁶⁵.

Kwotacja składki to finalny etap w procesie sprzedaży polisy ubezpieczeniowej, w którym ubezpieczyciel przedstawia klientowi ofertę cenową. Kwotacja uwzględnia wszystkie relewantne informacje o kliencie i jego potrzebach ubezpieczeniowych. Jest to moment, w którym klient może negocjować warunki polisy i dostosować ją do swoich indywidualnych potrzeb, na przykład poprzez wybór zakresu ochrony czy franszyzy.

Po zawarciu umowy ubezpieczyciele ciągle monitorują efektywność przyjętych modeli taryfikacyjnych i kwotacyjnych, dostosowując je w odpowiedzi na zmieniające się warunki rynkowe, wyniki finansowe oraz nowo pozyskiwane dane.

Proces taryfikacji i kwotacji składki ubezpieczeniowej jest kluczowym elementem zarządzania ryzykiem w towarzystwach ubezpieczeniowych. Taryfikacja pozwala na precyzyjne ustalenie składki na podstawie oceny ryzyka, zapewniając stabilność finansową towarzystwa ubezpieczeniowego. Kwotacja natomiast jest procesem zewnętrznym, który przedstawia klientowi wynik taryfikacji w formie oferty cenowej, umożliwiając sprzedaż produktu ubezpieczeniowego. Oba te procesy są nieodzowne dla funkcjonowania rynku ubezpieczeń, gwarantując adekwatne pokrycie ryzyka i satysfakcję klienta.

65

Np.: https://www.knf.gov.pl/knf/pl/komponenty/img/Rek_dot_procesu_ustalania_i_wyplaty_zadoscuczyn_z_tyt_szkody_niemajatkowej_z_umowOC_posiadaczy_pojazdow_mech_47349.pdf;
https://dziennikurzedowy.knf.gov.pl/DU_KNF/2023/22/akt.pdf

1.3. Dotychczasowe metody taryfikacji i kwotacji składki w ubezpieczeniach komunikacyjnych

Proces taryfikacji i kwotacji składki ubezpieczeniowej jest kluczowy dla stabilności finansowej towarzystw ubezpieczeniowych oraz ich konkurencyjności na rynku. Przez lata rozwijano różnorodne modele, mające na celu precyzyjne określenie ryzyka i dostosowanie wysokości składek do rzeczywistych zagrożeń. Choć tradycyjne metody taryfikacji, oparte na zaawansowanych modelach statystycznych, osiągnęły swoje apogeum rozwoju, to wciąż pozostają istotnym fundamentem w tej dziedzinie.

System bonus-malus stanowi jedno z najbardziej efektywnych narzędzi stosowanych w taryfikacji składek ubezpieczeniowych, zwłaszcza w sektorze ubezpieczeń komunikacyjnych. Jego głównym celem jest wprowadzenie finansowych zachęt i kar, które są bezpośrednio powiązane z historią szkodowości kierowcy. Systemy bonus-malus są kluczowym elementem zarządzania ryzykiem w ubezpieczeniach komunikacyjnych, a ich efektywność można mierzyć za pomocą różnych miar, takich jak analiza przejść między klasami taryfowymi z wykorzystaniem modelu Markowa. W literaturze przedmiotu podkreśla się, że model Markowa pozwala na efektywne przewidywanie zachowań ubezpieczonych, co jest kluczowe dla oceny stabilności taryf i optymalizacji systemu bonus-malus⁶⁶. Liczne badania wskazują, że system ten znacząco wpływa na poprawę bezpieczeństwa drogowego, promując ostrożniejszą jazdę, co z kolei przekłada się na redukcję liczby zgłaszanych roszczeń⁶⁷. Znaczenie tego systemu jest podkreślane w licznych badaniach, które wskazują, że skutecznie wpływa on na poprawę bezpieczeństwa drogowego poprzez promowanie ostrożniejszej jazdy⁶⁸. Polska literatura naukowa również podkreśla efektywność tego systemu. Wprowadzenie bonus-malus przyczynia się do obniżenia liczby roszczeń, co przekłada się na niższe koszty operacyjne oraz korzystniejsze warunki cenowe dla kierowców⁶⁹. System ten sprzyja także tworzeniu bardziej personalizowanych modeli taryfikacji, zgodnych z globalnymi trendami w zarządzaniu ryzykiem ubezpieczeniowym⁷⁰. Pamiętajmy, że system bonus-malus jest stosowany na całym świecie, jednak różne kraje dostosowują jego zasady do lokalnych uwarunkowań. Oto kilka przykładów jego stosowania:

⁶⁶ Jędrzychowska, A., & Poprawska, E. (2010). Analiza wybranych metod oceny systemów bonus-malus.

⁶⁷ Lemaire, J. (1995). Bonus-Malus Systems in Automobile Insurance. Kluwer Academic Publishers.

⁶⁸ tamże

⁶⁹ Szymańska, E. (2017). Zarządzanie ryzykiem w ubezpieczeniach komunikacyjnych. Polskie Wydawnictwo Ekonomiczne.

⁷⁰ Maruszewski, J. (2015). Ubezpieczenia majątkowe i osobowe. Wydawnictwo C.H. Beck, str. 112.

1) Francja

We Francji system bonus-malus jest stosowany w bardzo rygorystyczny sposób. Z każdym rokiem bezszkodowej jazdy, kierowca otrzymuje 5% zniżki na składkę ubezpieczeniową, aż do maksymalnie 50%. Z drugiej strony, każde zgłoszenie szkody powoduje zwiększenie składki o 25%. System ten motywuje kierowców do ostrożnej jazdy, a jego skuteczność jest widoczna w statystykach – Francja ma jedną z niższych średnich częstości roszczeń w Europie⁷¹.

2) Belgia

W Belgii system bonus-malus funkcjonuje z nieco innymi parametrami. Zniżki za bezszkodową jazdę są przyznawane w bardziej umiarkowany sposób, ale podobnie jak we Francji, system ten skutecznie reguluje poziom roszczeń. Belgia stosuje także dodatkowe zniżki za korzystanie z technologii wspomagających bezpieczeństwo, co jest dodatkowym czynnikiem motywującym do inwestycji w nowoczesne rozwiązania samochodowe⁷².

3) Japonia

Japonia wprowadziła system bonus-malus stosunkowo późno w porównaniu do Europy, ale jego wprowadzenie miało znaczący wpływ na rynek ubezpieczeń. System skoncentrowany jest na promowaniu bezpiecznej jazdy wśród młodych kierowców, którzy są uznawani za grupę o wysokim ryzyku. Bonusy są przyznawane za kursy doszkalające i bezszkodową jazdę, co wpływa na ogólną kulturę bezpieczeństwa na drogach⁷³.

Inny model kwotacji to **model regresji Poissona**. To popularna metoda statystyczna używana do modelowania zdarzeń liczonych, takich jak liczba roszczeń ubezpieczeniowych. Jest ona szczególnie przydatna, gdy zdarzenia te są rzadkie w stosunku do grupy obserwacji, a dane wykazują nadmierne zerowanie. Model regresji Poissona zakłada, że zmienna zależna, reprezentująca liczbę wystąpień danego zdarzenia, ma rozkład Poissona, który jest stosowany do modelowania zdarzeń o określonej średniej w jednostce czasu lub przestrzeni. W kontekście ubezpieczeń, jest to ilość roszczeń w określonym czasie. Model wyraża logarytm średniej liczby zdarzeń jako liniową

⁷¹ Lemaire, J. (1995).

⁷² Casualty Actuarial Society. (2023). Bonus-Malus Systems: The European and Asian Approach to Merit-Rating, <https://www.casact.org>

⁷³ tamże

kombinację zmiennych niezależnych⁷⁴. W praktyce aktuarialnej, model regresji Poissona jest stosowany do szacowania liczby roszczeń na podstawie różnych czynników ryzyka. Pozwala to ubezpieczycielom na bardziej precyzyjne ustalanie składek ubezpieczeniowych, dostosowanych do indywidualnego ryzyka każdego klienta.

Model ten pozwala na analizę wpływu takich czynników jak wiek pojazdu, historia wypadków, czy miejsce zamieszkania na prawdopodobieństwo wystąpienia roszczeń. Na przykład, badania pokazują, że kierowcy młodszy oraz ci z historią roszczeń są skłonni do wyższej częstotliwości roszczeń, co model regresji Poissona może precyzyjnie odzwierciedlić⁷⁵. Model regresji Poissona jest więc potężnym narzędziem w rękach aktuariuszów i analityków ryzyka, umożliwiającym bardziej precyzyjne i sprawiedliwe podejście do ustalania składek ubezpieczeniowych. Jego zastosowanie pozwala na poprawę zarządzania ryzykiem oraz optymalizację procesów decyzyjnych w branży ubezpieczeniowej.

Model regresji Poissona jest szeroko stosowany w branży ubezpieczeniowej do precyzyjnego oszacowania ryzyka związanego z indywidualnymi polisami. Przykłady jego zastosowania obejmują zarówno analizę ryzyka wypadkowego pojazdów, jak i modelowanie częstości występowania roszczeń związanych z innymi typami polis. W ubezpieczeniach komunikacyjnych, model regresji Poissona jest używany do oszacowania liczby roszczeń, które mogą wystąpić w przyszłości na podstawie danych historycznych. Analiza może uwzględniać następujące parametry, co obrazuje tabela 2.

Tabela 2

Parametry analizy w modelu regresji Poissona

parametry analizy	wnioski
wiek i doświadczenie kierowcy	młodszy kierowcy lub ci z krótkim stażem mogą mieć wyższą przewidywaną liczbę roszczeń
historia roszczeń	kierowcy z historią roszczeń są bardziej skłonni do ich powtórzenia
typ i wiek pojazdu	starsze pojazdy lub modele znane z częstszych awarii mogą wykazywać wyższą częstotliwość roszczeń

Źródło: opracowanie własne

⁷⁴ Cameron, A. C., & Trivedi, P. K. (2013). Regression analysis of count data (Vol. 53). Cambridge University Press.

⁷⁵ Hilbe, J. M. (2011). Negative binomial regression (2nd ed.). Cambridge University Press.

Przykładowe badanie przeprowadzone przez Ayuso, Guillen, i Alcañiz wykorzystało model regresji Poissona do analizy wpływu wieku i doświadczenia na częstość roszczeń w ubezpieczeniach samochodowych⁷⁶.

Kolejny model określany jest jako **model zliczeń z nadmiarem zer**, znane również jako **zero-inflated models**. Są szczególnie przydatne w sytuacjach, gdy analizowane dane zawierają więcej zer (tj. brak wystąpienia zdarzenia) niż przewidywałby standardowy model zliczeń, takich jak model Poissona czy model binominalny ujemny. Te modele są wykorzystywane w różnych dziedzinach, w tym w ubezpieczeniach, gdzie duża część klientów może nie zgłaszać żadnych roszczeń.

Modele z nadmiarem zer łączą dwa procesy decyzyjne: jeden dla generowania zer wynikających z dodatkowego procesu (tzw. "true zeros"), a drugi dla generowania zliczeń, w tym zer, z typowego rozkładu zliczeń, jak Poissona lub ujemnego binomu.

Dwa główne modele to:

- Zero-inflated Poisson (ZIP),
- Zero-inflated Negative Binomial (ZINB).

Model ZIP jest stosowany, gdy wariancja liczby zdarzeń jest równa średniej (tj., gdy dane wykazują równomierny rozkład), natomiast ZINB jest używany, gdy wariancja przewyższa średnią, co wskazuje na nadmierną dyspersję w danych. W ubezpieczeniach, modele te są użyteczne do analizowania danych z dużą liczbą polis bez roszczeń. Pozwalają one na lepsze dostosowanie ryzyka i ustalenie składek dla grup klientów, którzy rzadko zgłaszają roszczenia. Dzięki zastosowaniu tych modeli, ubezpieczyciele mogą dokładniej przewidywać ryzyko i zarządzać portfelem polis⁷⁷.

Modele z nadmiarem zer pozwalają na precyzyjniejsze oszacowanie prawdopodobieństwa wystąpienia roszczeń w populacjach z dużą liczbą klientów bezszkodowych. Umożliwiają one rozróżnienie między klientami, którzy prawdopodobnie nigdy nie zgłoszą roszczenia, a tymi, którzy nie zgłosili roszczenia przypadkowo.

Dzięki dokładniejszemu modelowaniu, ubezpieczyciele mogą bardziej precyzyjnie ustalać wysokość składek, co przekłada się na bardziej konkurencyjne oferty i możliwość

⁷⁶ Ayuso, M., Guillen, M., & Alcañiz, M. (2016). Automobile insurance: actuarial models. The European Actuarial Journal.

⁷⁷ Lambert, D. (1992). Zero-inflated Poisson regression, with an application to defects in manufacturing. Technometrics, 34(1), 1-14.

oferowania niższych cen dla klientów niskiego ryzyka. To z kolei może przyciągnąć nowych klientów i zwiększyć ich zadowolenie.

Modelowanie z nadmiarem zer jest kluczowym narzędziem w nowoczesnym zarządzaniu ryzykiem ubezpieczeniowym, pozwalającym na bardziej zaawansowaną analizę danych i lepsze dostosowanie produktów ubezpieczeniowych do potrzeb klientów.

Pisząc o aktualnych metodach taryfikacji nie można nie wspomnieć o pewnych innowacjach w taryfikacji a posteriori. Rozwój technologii, takich jak telematyka, umożliwia ubezpieczycielom personalizację składek na podstawie rzeczywistych danych dotyczących stylu jazdy kierowców. Taryfikacja a posteriori opiera się na zbieraniu i analizie danych z urządzeń telematycznych, co pozwala na dynamiczne dostosowywanie składek do indywidualnego ryzyka⁷⁸. Nowoczesne algorytmy uczenia maszynowego zyskują na znaczeniu w procesie taryfikacji i kwotacji składek ubezpieczeniowych. Algorytmy te umożliwiają analizę dużych zbiorów danych i identyfikację ukrytych wzorców, co przyczynia się do optymalizacji taryfikacji składek⁷⁹. W kontekście ubezpieczeń komunikacyjnych, zastosowanie algorytmów uczenia maszynowego umożliwia przewidywanie przyszłych zachowań kierowców oraz bardziej precyzyjną ocenę ryzyka.

Mimo, że tradycyjne metody taryfikacji, takie jak modele statystyczne i aktuarialne, są szeroko stosowane, mają one swoje ograniczenia. Modele te wymagają dużych zbiorów danych historycznych oraz regularnego dostosowywania do zmieniających się warunków rynkowych i technologicznych. Tradycyjne modele powinny być uzupełniane o nowoczesne technologie, takie jak telematyka i big data, aby sprostać nowym wyzwaniom rynkowym⁸⁰.

⁷⁸ Malinowska, K. (2019). Ocena ryzyka w ubezpieczeniach a nowe technologie w kontekście zasad umowy ubezpieczenia. Warszawa: Wolters Kluwer, str. 78.

⁷⁹ Gupta, P. K. (2020). Essentials of Insurance and Risk Management. Wydawnictwo Cengage Learning.

⁸⁰ Jędrzychowska, A. (2020). Nowoczesne metody taryfikacji w ubezpieczeniach komunikacyjnych. Wydawnictwo Uniwersytetu Ekonomicznego we Wrocławiu, Ronka-Chmielowiec, W. (2017). Ubezpieczenia. Ryzyko i zarządzanie ryzykiem. Wydawnictwo C.H. Beck.

1.4.Uzasadnienie potrzeby opracowania nowej metody taryfikacji i kwotacji składki w towarzystwach ubezpieczeniowych

Tradycyjne metody taryfikacji, oparte głównie na danych historycznych, nie zawsze są dostosowane do dynamicznie zmieniającego się otoczenia rynkowego. Współczesny rynek ubezpieczeń komunikacyjnych napotyka liczne wyzwania związane z adekwatnością oraz stabilnością składek ubezpieczeniowych. Wprowadzenie nowych technologii, takich jak sztuczna inteligencja (AI) oraz telematyka, może zaoferować bardziej precyzyjną i dynamiczną taryfikację. Przykłady innowacyjnych podejść ukazują, że wykorzystanie big data i AI umożliwia bardziej trafne i sprawiedliwe ustalanie składek ubezpieczeniowych⁸¹. W Polsce takie innowacje są nadal w fazie wdrażania, co stwarza pole do opracowania nowych metod, które lepiej odpowiadają na aktualne potrzeby rynku ubezpieczeniowego.

Jest to niezwykle ważne z uwagi na wyzwania związane z adekwatnością składek ubezpieczeniowych. Aktualnie stosowane metody taryfikacji i kwotacji składek często nie odpowiadają dynamicznie zmieniającym się warunkom rynkowym oraz rosnącym kosztom szkód i likwidacji. Komisja Nadzoru Finansowego w swoim stanowisku z 2019 roku wyraźnie podkreśla, że istniejące procesy taryfikacji wymagają przeglądu i optymalizacji w celu zapewnienia, że składki są adekwatne do ponoszonego ryzyka⁸². KNF zwraca uwagę, że procesy taryfikacji muszą być systematycznie przeglądane, aby dostosować się do zmieniających się warunków rynkowych i regulacyjnych.

Przegląd ten powinien obejmować następujące elementy:

- 1) analizę danych szkodowych,
- 2) weryfikację stosowanych modeli aktuarialnych,
- 3) ocena adekwatności składek,
- 4) optymalizacja procesów taryfikacji.

Analiza danych szkodowych

Systematyczne zbieranie i analiza danych dotyczących szkód, w tym częstotliwości i wartości roszczeń. Dane te powinny być aktualizowane i analizowane w kontekście zmieniających się warunków rynkowych, takich jak wprowadzenie nowych technologii, zmiany w przepisach drogowych czy zmieniające się nawyki kierowców.

⁸¹ Lemonade.com

⁸² Komisja Nadzoru Finansowego (2019). Stanowisko KNF dotyczące adekwatności składek w ubezpieczeniach komunikacyjnych.

Weryfikacja stosowanych modeli aktuarialnych

Ocena skuteczności stosowanych modeli aktuarialnych i ich dostosowanie do bieżących potrzeb rynkowych. Modele te powinny być regularnie aktualizowane, aby uwzględniać najnowsze dane oraz zmieniające się ryzyka. KNF sugeruje, aby ubezpieczyciele korzystali z zaawansowanych narzędzi analitycznych i technologii, takich jak big data i sztuczna inteligencja, w celu lepszego przewidywania ryzyk.

Ocena adekwatności składek

Regularna ocena, czy obecne składki są adekwatne do pokrycia kosztów szkód i innych zobowiązań finansowych. KNF podkreśla, że składki muszą być ustalane w sposób, który zapewnia stabilność finansową zakładów ubezpieczeń oraz ich zdolność do wywiązywania się z zobowiązań wobec klientów.

Optymalizacja procesów taryfikacji

Optymalizacja procesów taryfikacji ma na celu zwiększenie efektywności i dokładności w ustalaniu składek. KNF zaleca następujące kroki:

1) Wdrożenie nowoczesnych technologii

Ubezpieczyciele powinni wdrażać nowoczesne technologie, takie jak IoT, telematyka, i systemy AI, które pozwalają na zbieranie i analizowanie szczegółowych danych o zachowaniach kierowców w czasie rzeczywistym. Technologia ta umożliwia bardziej precyzyjne ustalanie składek na podstawie rzeczywistych zachowań użytkowników pojazdów.

2) Personalizacja składek

Stosowanie bardziej spersonalizowanych taryf, które uwzględniają indywidualne cechy i zachowania kierowców. Dzięki temu, składki mogą być bardziej sprawiedliwe i adekwatne do rzeczywistego ryzyka, co może zachęcać kierowców do bezpieczniejszej jazdy.

3) Przeprowadzanie regularnych audytów,

KNF rekomenduje regularne przeprowadzanie audytów procesów taryfikacji, aby zapewnić ich zgodność z najlepszymi praktykami rynkowymi i regulacyjnymi. Audyty te powinny identyfikować obszary do poprawy oraz monitorować efektywność wdrożonych zmian.

4) Wynik techniczny zakładów ubezpieczeń,

Wynik techniczny to jeden z kluczowych wskaźników oceny kondycji finansowej zakładów ubezpieczeń, który obrazuje różnicę między przychodami z tytułu składek a kosztami związanymi z likwidacją szkód i rezerwami technicznymi. Raport UOKiK z

2018 roku wskazuje, że wynik techniczny zakładów ubezpieczeń komunikacyjnych w Polsce od kilku lat pozostaje niestabilny i nieprzewidywalny. Analiza wyników technicznych za ostatnie lata ujawnia, że wiele zakładów ubezpieczeń notuje straty techniczne, co wskazuje na problemy z adekwatnym ustalaniem składek w stosunku do ponoszonego ryzyka⁸³. Brak stabilności i przewidywalności w kalkulacjach składek wynika z kilku kluczowych czynników:

a. Niedoszacowanie ryzyka

Aktualne metody taryfikacji nie zawsze uwzględniają wszystkie istotne czynniki ryzyka, co prowadzi do ustalania składek, które nie pokrywają rzeczywistych kosztów szkód. Ubezpieczyciele często bazują na historycznych danych, które mogą nie odzwierciedlać bieżących warunków rynkowych ani indywidualnych zachowań kierowców.

b. Dynamicznie zmieniające się warunki rynkowe

Rynek ubezpieczeń komunikacyjnych jest bardzo dynamiczny, a zmiany w prawodawstwie, technologii oraz zachowaniach konsumentów mogą szybko wpłynąć na ryzyko i koszty. Obecne modele nie są wystarczająco elastyczne, aby szybko reagować na te zmiany.

c. Wysokie koszty likwidacji szkód

Rosnące koszty likwidacji szkód, w tym koszty napraw, odszkodowań oraz zarządzania rezerwami, często przekraczają przewidywane wartości, co prowadzi do strat technicznych.

Taka sytuacja niestabilności i nieprzewidywalności w kalkulacjach składek ma bezpośredni wpływ na wypłacalność i stabilność finansową zakładów ubezpieczeń. Prowadzi to oczywiście do strat technicznych. Regularne notowanie strat technicznych wskazuje, że przychody ze składek są niewystarczające do pokrycia kosztów związanych z likwidacją szkód i rezerwami. To zagraża wypłacalności zakładów ubezpieczeń, ponieważ nie mają one wystarczających funduszy na pokrycie swoich zobowiązań.

d. Ryzyko niewypłacalności

Długotrwałe problemy z adekwatnym ustalaniem składek mogą prowadzić do ryzyka niewypłacalności. Zakłady ubezpieczeń, które nie są w stanie pokryć swoich zobowiązań, mogą nie być w stanie wywiązać się z umów ubezpieczeniowych, co zagraża interesom klientów.

⁸³ Urząd Ochrony Konkurencji i Konsumentów (2018). Raport UOKiK o stanie rynku ubezpieczeń komunikacyjnych.

Reasumując, wskazać należy, że tradycyjne metody taryfikacji składek ubezpieczeniowych opierające się na danych historycznych oraz wskaźnikach statystycznych są niewystarczające do precyzyjnej oceny rzeczywistego ryzyka. W systemach ubezpieczeń komunikacyjnych, klasyczne podejście taryfikacyjne jest ograniczone przez brak dostępu do danych o bieżącym użytkowaniu pojazdów, co powoduje, że wycena składek jest jedynie przybliżeniem, opartym na prognozach historycznych i standardowych zmiennych demograficznych. Taka statyczna struktura analizy nie odpowiada współczesnym potrzebom dynamicznego i elastycznego rynku ubezpieczeń, gdzie coraz większą rolę odgrywa personalizacja i precyzja oceny ryzyka. Z tego względu konieczne jest opracowanie nowej metody, która wykorzystuje aktualne technologie oraz dane zebrane w czasie rzeczywistym, zapewniając bardziej rzetelną taryfikację.

W rozdziale pierwszym zrealizowano cel teoretyczny pracy, przedstawiając przegląd dotychczasowych metod taryfikacji i kwotacji składek w ubezpieczeniach komunikacyjnych oraz ich ograniczenia. Omówiono podstawowe koncepcje, takie jak tradycyjne modele oparte na statystykach historycznych oraz rolę danych demograficznych. Rozdział pokazuje, że dotychczasowe rozwiązania nie uwzględniają specyfiki rzeczywistych zachowań kierowców, co prowadzi do nieprecyzyjnych ocen ryzyka. Wskazano konieczność wprowadzenia nowych metod opartego na rzeczywistych danych, takich jak te pochodzące z telemetrii, aby lepiej dopasować oferty ubezpieczeń do rzeczywistych potrzeb klientów.

2. Istota wykorzystania nowoczesnych technologii w towarzystwach ubezpieczeniowych

2.1. Nowe technologie w rozwoju ubezpieczeń komunikacyjnych towarzystw ubezpieczeniowych

Współczesny sektor ubezpieczeń dynamicznie się zmienia, głównie za sprawą wdrażania nowoczesnych technologii, które rewolucjonizują sposób zarządzania ryzykiem, obsługi klientów oraz procesów back-office. Technologie takie jak sztuczna inteligencja (AI), uczenie maszynowe (ML), Internet Rzeczy (IoT) oraz narzędzia telematyczne wpływają na wzrost efektywności operacyjnej, lepsze dostosowanie ofert do potrzeb klientów oraz automatyzację procesów likwidacji szkód.

Na rynkach globalnych, takich jak USA, Wielka Brytania, Japonia czy Australia, te innowacje przekształciły sposób działania towarzystw ubezpieczeniowych, umożliwiając im szybsze i bardziej efektywne reagowanie na potrzeby klientów. Dzięki ML i AI możliwe jest nie tylko zwiększenie precyzji w ocenie ryzyka, ale także optymalizacja procesów wewnętrznych oraz personalizacja ofert ubezpieczeniowych dla klientów. Na przykładzie USA można zobaczyć, jak firmy, takie jak Lemonade z powodzeniem wykorzystują AI do automatyzacji procesów underwritingowych oraz przyspieszenia wypłat odszkodowań⁸⁴. Podobne tendencje można zaobserwować w Wielkiej Brytanii, gdzie np. Aviva wprowadziła AI do analizy ryzyka i personalizacji ofert⁸⁵. Profilowanie stylu jazdy kierowców z wykorzystaniem metod maszynowego uczenia, takich jak analiza klasteryzacji czy algorytmy klasyfikacyjne, stanowi kluczowy element nowoczesnych systemów oceny ryzyka w ubezpieczeniach komunikacyjnych. Dzięki zastosowaniu tych technik, firmy ubezpieczeniowe mogą dokładniej modelować zachowania kierowców na podstawie danych telematycznych, co prowadzi do bardziej precyzyjnego ustalania taryfikacji składek oraz poprawy efektywności zarządzania ryzykiem.

Profilowanie stylu jazdy kierowców może obejmować pełny wektor wyliczanych metryk albo tylko jego podzbiór. Mając na uwadze triangulację metod, w niniejszej pracy

⁸⁴ Adams, C. (2020). Artificial Intelligence and the Insurance Industry. *North American Journal of Insurance and Finance*, 15(2), 140-158.

⁸⁵ Johnson, R. (2021). The Role of AI in Insurance Risk Management. *European Journal of Risk Management*, 19(4), 220-239.

przeanalizowano następujące technologie komunikacji zdalnej oraz technologie sztucznej inteligencji (przede wszystkim maszynowego uczenia):

- analiza klasteryzacji K-Means Clustering,
- klasteryzacja hierarchiczna (Hierarchical Clustering),
- algorytmy klasyfikacyjne Random Forest,
- Support Vector Machines (SVM),
- analiza szeregów czasowych,
- podejście hybrydowe.

Technologie te mogą być zastosowane do opracowania metody taryfikacji i kwotacji składki ubezpieczeniowej i zostaną szczegółowo przeanalizowane w podrozdziale 2.2 i 2.3.

2.2. Technologie Komunikacji Zdalnej

Technologie komunikacji zdalnej, takie jak aplikacje mobilne, platformy internetowe oraz rozwiązania internetu rzeczy, zyskują na znaczeniu w branży ubezpieczeń. Umożliwiają one towarzystwom ubezpieczeniowym szybszą i bardziej efektywną obsługę klientów, co jest kluczowe w konkurencyjnym środowisku rynkowym.

GEICO i Progressive zintegrowały aplikacje mobilne i platformy internetowe z pełną obsługą klienta. Klienci mogą zarządzać swoimi polisami, zgłaszać szkody oraz korzystać z usług doradczych w czasie rzeczywistym. Wprowadzenie chatbotów i narzędzi AI do tych aplikacji znacząco skraca czas reakcji i poprawia satysfakcję klientów⁸⁶. Aviva wdrożyła zaawansowane narzędzia do zarządzania roszczeniami, które pozwalają klientom na zdalne zgłaszanie szkód, monitorowanie statusu roszczeń oraz uzyskiwanie wycen w czasie rzeczywistym. Integracja tych technologii poprawiła efektywność procesów oraz zmniejszyła liczbę błędów wynikających z ręcznego przetwarzania danych⁸⁷.

Jednym z kluczowych elementów współczesnych technologii komunikacji zdalnej w sektorze ubezpieczeń komunikacyjnych jest Internet Rzeczy (IoT). IoT umożliwia

⁸⁶ Smith, J. (2020). Advances in Mobile Insurance Technology. *Journal of Insurance Technology*, 12(3), 45-67. Brown, A. (2019). Digital Transformation in the Insurance Sector. *Insurance Review*, 27(2), 112-130

⁸⁷ Johnson, R. (2021).

Taylor, L. (2020). Innovation in Insurance: The Case of Aviva. *Journal of Financial Services*, 28(1), 88-104.

gromadzenie, przesyłanie i analizowanie danych z pojazdów w czasie rzeczywistym, co znacząco wpływa na proces taryfikacji i oceny ryzyka ubezpieczeniowego.

Internet of Things (IoT) to sieć połączonych ze sobą urządzeń, które mogą gromadzić i przysyłać dane bez interwencji człowieka. W sektorze ubezpieczeń komunikacyjnych najczęściej są to telematyczne moduły montowane w pojazdach lub aplikacje mobilne, które monitorują styl jazdy kierowców, liczbę przejazdów, prędkość, gwałtowne hamowania oraz przyspieszenia. Dane te pozwalają ubezpieczycielom na bardziej precyzyjną ocenę ryzyka i umożliwiają dynamiczną kalkulację składki, dostosowaną do rzeczywistego zachowania kierowcy.

W ostatnich latach zauważono wyraźny wzrost wykorzystania technologii IoT w sektorze ubezpieczeń komunikacyjnych. Według raportu Telematics Technologies (2022), aż 62% nowych samochodów sprzedanych na świecie w 2020 roku było wyposażonych w systemy telematyczne OEM (Original Equipment Manufacturer), a w regionie UE+EFTA udział ten wyniósł 72% (Telematics Technologies, 2022)⁸⁸.

Jednakże wciąż 30-40% nowych samochodów nie jest wyposażonych w takie systemy, co oznacza, że urządzenia aftermarketowe (instalowane po zakupie samochodu) pozostaną istotnym źródłem danych telemetrycznych dla ubezpieczycieli przez najbliższe lata. Korzystanie z IoT pozwala na gromadzenie szczegółowych danych, takich jak dzienne i nocne przejazdy, średnia prędkość czy gwałtowne manewry, co umożliwia tworzenie bardziej spersonalizowanych i adekwatnych ofert ubezpieczeniowych.

Technologia IoT nie tylko umożliwia lepszą ocenę ryzyka, ale także pozwala na automatyzację procesów wewnętrznych ubezpieczycieli, takich jak zarządzanie likwidacją szkód czy identyfikacja prób wyłudzeń odszkodowań. To z kolei przekłada się na obniżenie kosztów operacyjnych i może prowadzić do bardziej konkurencyjnych ofert dla klientów.

Na przykład w Finlandii Sompo Holdings wykorzystuje telematykę do monitorowania zachowań kierowców, co pozwala na precyzyjne dostosowanie składki ubezpieczeniowych do indywidualnego ryzyka. Dane przesyłane z pojazdów w czasie rzeczywistym pomagają w identyfikacji ryzykownych zachowań, co z kolei przyczynia się do zmniejszenia liczby wypadków⁸⁹. Safeco RightTrack to innowacyjny program

⁸⁸ Telematics Technologies. (2022). *The Future of Auto Insurance Telematics*. Telematics Technologies

⁸⁹ Nakamura, T. (2018). Telematics and the Future of Insurance in Japan. *Asia-Pacific Insurance Journal*, 16(2), 155-172.

ubezpieczeniowy, który wykorzystuje technologię telematyczną do monitorowania zachowań kierowców. Jego celem jest bardziej precyzyjna ocena ryzyka i dostosowanie wysokości składek ubezpieczeniowych do indywidualnych zachowań za kierownicą. Program polega na instalacji niewielkiego urządzenia telematycznego w samochodzie ubezpieczonego. Urządzenie to rejestruje różne aspekty jazdy, takie jak:

- przyspieszanie i hamowanie – gwałtowne przyspieszanie i hamowanie może wskazywać na bardziej ryzykowny styl jazdy,
- prędkość – monitorowanie prędkości pozwala ocenić, czy kierowca przestrzega ograniczeń prędkości,
- czas jazdy – jazda nocą lub w godzinach szczytu może wiązać się z większym ryzykiem, co jest uwzględniane w analizie danych,
- łączny czas spędzony za kierownicą – dłuższy czas jazdy może zwiększać ryzyko zmęczenia, co również wpływa na ocenę ryzyka.

Dane zebrane przez urządzenie są analizowane, a wyniki przekładają się na obniżenie składek dla kierowców, którzy wykazują się bezpiecznym stylem jazdy. Program oferuje nawet do 30% zniżki na składki ubezpieczeniowe za bezpieczną jazdę⁹⁰. Jakie korzyści generuje program RightTrack? Dzięki zebranych danym, ubezpieczyciel może dostosować składki do indywidualnych zachowań kierowcy, co jest bardziej sprawiedliwe niż tradycyjne metody kalkulacji. Program motywuje kierowców do bezpieczniejszych zachowań za kierownicą, co może prowadzić do mniejszej liczby wypadków. Urządzenie jest łatwe do zainstalowania, a dane można śledzić na bieżąco przez aplikację mobilną, co daje użytkownikom pełną kontrolę nad swoimi wynikami. Należy stwierdzić, że rozwiązania oparte o IoT-enabled sensors wykorzystywane do monitorowania takich parametrów jak prędkość, przyspieszenie, obrót kierownicy, temperatura silnika czy poziom oleju pozwalają na bardziej precyzyjne zarządzanie ryzykiem poprzez np. wczesne wykrywanie potencjalnych problemów technicznych w pojazdach, co może zapobiec poważnym awariom i związanym z nimi roszczeniom ubezpieczeniowym.

Coraz większą rolę w ocenie szkód i zarządzaniu ryzykiem, szczególnie w ubezpieczeniach majątkowych odgrywają drony. Mogą one przeprowadzać inspekcje

Suzuki, M. (2019). Leveraging Big Data in Telematics Insurance. *Japanese Journal of Risk and Insurance*, 14(3), 78-95.

⁹⁰ <https://www.righttrack.safeco.com/HowItWorks.aspx>

trudno dostępnych miejsc, takich jak dachy czy duże pola uprawne, co przyspiesza proces roszczeń i zwiększa dokładność oceny. Do końca 2023 roku mieliśmy blisko 450k dronów komercyjnych wykorzystywanych również w ubezpieczeniach⁹¹.

Nie sposób odnotować również zmiany w podejściu firm ubezpieczeniowych do procesów opartych o nowe technologie. Coraz częściej zamiast tworzyć systemy od podstaw, coraz więcej firm wykorzystuje platformy niskokodowe (Low-Code Development), które pozwalają na szybkie tworzenie aplikacji z wykorzystaniem interfejsów graficznych i narzędzi typu "przeciągnij i upuść". To pozwala firmom na szybsze wprowadzanie nowych produktów na rynek i dostosowywanie się do zmieniających się potrzeb klientów⁹².

W Polsce technologie komunikacji zdalnej są rozwijane, choć jeszcze nie osiągnęły poziomu zaawansowania widocznego na rynkach zachodnich. Przykładem jest aplikacja mobilna mojePZU, która pozwala użytkownikom na pełne zarządzanie polisami, zgłaszanie szkód oraz korzystanie z usług medycznych. Za pomocą aplikacji ubezpieczeni mogą przeglądać, modyfikować i odnawiać polisy, zgłaszać szkodę czy skorzystać z telemedycyny. Bezpieczeństwo danych użytkownika zapewnia dostęp z użyciem biometrii⁹³.

Równie szeroką funkcjonalność oferuje aplikacja CUK, która pozwala użytkownikom na:

- przechowywanie wszystkich polis w jednym miejscu, zarówno tych kupionych w CUK, jak i u innych ubezpieczycieli,
- zakup nowej polisy, aplikacja umożliwia porównanie ofert OC/AC, nieruchomości, zdrowotnych oraz turystycznych, a następnie szybki zakup online,
- wezwanie pomocy drogowej – użytkownik może jednym kliknięciem wezwać assistance, zgłosić szkodę lub sprawdzić polisę OC sprawcy wypadku. Funkcje takie jak przypomnienia o zbliżającym się terminie odnowienia polisy pomagają utrzymać pełną ochronę ubezpieczeniową⁹⁴.

Aplikacja Mubi jest kolejnym przykładem narzędzia, które pozwala użytkownikom na szybkie porównanie i zakup ubezpieczeń. Oferuje kalkulator ubezpieczeniowy, który pozwala na analizę ofert wielu towarzystw jednocześnie, co ułatwia wybór

⁹¹ <https://www.vlinkinfo.com/blog/9-innovative-insurance-technology-trends/>

⁹² <https://global.hitachi-solutions.com/blog/insurance-technology-trends/>

⁹³ <https://moje.pzu.pl>

⁹⁴ <https://cuk.pl/aplikacja>

najkorzystniejszej polisy. Dodatkowo aplikacja oferuje przypomnienia o kończących się polisach oraz możliwość zarządzania wszystkimi dokumentami ubezpieczeniowymi w jednym miejscu⁹⁵.

Te wdrożenia stanowią krok w stronę zwiększenia efektywności operacyjnej i konkurencyjności na rynku ubezpieczeń w Polsce⁹⁶.

2.3. Technologie Sztucznej Inteligencji

Sztuczna inteligencja (AI) jest coraz bardziej wykorzystywana w sektorze ubezpieczeń do analizy danych, automatyzacji procesów underwritingowych, personalizacji ofert ubezpieczeniowych oraz obszaru likwidacji szkód. Przykłady z tych samych rynków pokazują, jak AI przekształca sektor ubezpieczeń, wpływając na szybkość i precyzję procesów oraz na obniżenie kosztów operacyjnych. Lemonade wykorzystuje AI do automatyzacji procesów underwritingowych oraz natychmiastowej wypłaty odszkodowań. Algorytmy AI analizują wnioski o odszkodowania i podejmują decyzje w ciągu sekund, co skraca czas oczekiwania klientów i obniża koszty operacyjne⁹⁷. Aviva stosuje AI do personalizacji ofert ubezpieczeniowych oraz analizy ryzyka. AI pozwala na lepsze dopasowanie polis do potrzeb klientów, co zwiększa ich satysfakcję oraz poprawia rentowność ubezpieczyciela⁹⁸. Tokio Marine wykorzystuje AI do analizy danych telematycznych z pojazdów, co umożliwia precyzyjną ocenę ryzyka oraz optymalizację taryfikacji składek. AI pomaga również w identyfikacji oszustw ubezpieczeniowych, co zmniejsza straty finansowe ubezpieczyciela⁹⁹. Jako ciekawostkę wspomnę, że w Iranie wdrożono systemy oparte na sztucznej inteligencji do oceny ryzyka ubezpieczeń komunikacyjnych. Systemy te wykorzystują AI do analizy dużych zbiorów danych, co pozwala na bardziej precyzyjną ocenę ryzyka i optymalizację składek¹⁰⁰.

W obszarze likwidacji szkód rozwój technologii obejmuje kilka głównych klas rozwiązań, które znacząco zmieniają sposób, w jaki towarzystwa ubezpieczeniowe

⁹⁵ <https://mubi.pl>

⁹⁶ Kowalski, P. (2021). Technologie AI w polskim sektorze ubezpieczeń. *Journal of Polish Insurance Studies*, 8(1), 45-62.

⁹⁷ White, D. (2021). Disrupting the Insurance Market with AI: The Lemonade Example. *Insurance Innovations*, 22(5), 67-83

⁹⁸ Johnson R. (2021).

⁹⁹ https://www.tokiomarinehd.com/en/ir/event/presentation/2023/k82ffv000000gws-att/Interim_IR_conference_FY2023_e.pdf

¹⁰⁰ Mohammadi, M., Gandomi, A. H., & Shabani, M. (2023). Car Insurance Risk Assessment with Data Mining Techniques in Iran

przetwarzają zgłoszenia i obsługują klientów. Można je podzielić na **trzy podstawowe kategorie**:

- 1) rozwiązania oparte na sztucznej inteligencji (AI), w tym generatywnej AI i modelach językowych (LLM) – te narzędzia rozszerzają możliwości istniejących systemów, automatyzując procesy, które wcześniej były realizowane ręcznie; AI wspiera weryfikację zgłoszeń oraz analizę danych, umożliwiając dokładniejsze oceny ryzyka;
- 2) systemy wspomagające back-office, jak ocena ryzyka czy raportowanie – umożliwiają one automatyzację analiz, optymalizując procesy administracyjne i pozwalając na sprawniejsze zarządzanie roszczeniami;
- 3) narzędzia do samolikwidacji szkód, które oddają klientowi część odpowiedzialności za proces zgłoszenia szkody – dzięki aplikacjom mobilnym klienci mogą sami dokumentować szkody (np. za pomocą zdjęć), a systemy te automatycznie aktualizują status zgłoszenia, zapewniając pełną transparentność.

Wśród **trendów wspierających likwidację** szkód można wyróżnić:

- AI do wykrywania oszustw: algorytmy uczą się na podstawie historycznych danych i analizują zgłoszenia, aby identyfikować anomalie wskazujące na możliwe przypadki oszustw. Rozwiązania te pomagają obniżyć koszty związane z wymuszeniami i innymi nieprawidłowościami w roszczeniach.
- Automatyczni konsultanci (chatboty i voiceboty): stosowane są przede wszystkim do obsługi prostych zapytań i informowania klientów o statusie zgłoszenia. Ich rozwój doprowadził do znacznej poprawy jakości usług, ponieważ są one dostępne 24/7 i mogą natychmiastowo reagować na zapytania klientów, co zwiększa efektywność obsługi klienta.
- Samolikwidacja szkód: aplikacje mobilne i portale klienta pozwalają użytkownikom samodzielnie przysyłać dokumentację fotograficzną oraz monitorować status szkody. Tego rodzaju rozwiązania skracają czas obsługi zgłoszenia i zwiększają satysfakcję klienta, który czuje większą kontrolę nad procesem¹⁰¹.
- OCR i AI do analizy dokumentów: kombinacja technologii OCR (optyczne rozpoznawanie znaków) i sztucznej inteligencji umożliwia automatyczną analizę

¹⁰¹ https://www.pzu.pl/_files/1548650

dokumentów, np. medycznych, i podejmowanie decyzji o wysokości świadczeń bez udziału człowieka.

- Visual AI do oceny uszkodzeń: rozwiązania te analizują zdjęcia szkód, np. uszkodzeń pojazdów w wypadkach komunikacyjnych czy zniszczeń nieruchomości i automatycznie generują wstępną wycenę. Takie narzędzia są szczególnie użyteczne w przyspieszaniu procesu likwidacji szkód.

Nowoczesne technologie, takie jak sztuczna inteligencja, telematyka, aplikacje mobilne oraz platformy low-code, odgrywają kluczową rolę w transformacji sektora ubezpieczeń¹⁰². Wdrożenie AI do procesów likwidacji szkód, personalizacji ofert oraz zarządzania polisami pozwala towarzystwom ubezpieczeniowym na zwiększenie efektywności operacyjnej oraz lepszą obsługę klientów. W Polsce technologia ta dopiero się rozwija, jednak przykład firm takich jak PZU czy CUK pokazuje, że nowoczesne narzędzia zyskują na znaczeniu, poprawiając efektywność operacyjną i satysfakcję klientów co może w przyszłości znacząco poprawić efektywność operacyjną oraz konkurencyjność polskich towarzystw ubezpieczeniowych¹⁰³.

W dalszej części podrozdziału zostaną przeanalizowane **technologie sztucznej inteligencji**, które mogą być wykorzystane w budowie metody taryfikacji i kwotacji składki ubezpieczeniowej.

— Analiza klasteryzacji K-Means Clustering¹⁰⁴

Metoda może być używany do grupowania kierowców na podstawie wybranych metryk. Algorytm ten automatycznie i bez nadzoru identyfikuje, do którego zbioru dany kierowca należy.

W najkrótszym skrócie K-Means działa w następujący sposób:

- 1) wybór liczby klastrow (k) – użytkownik wybiera liczbę klastrow k, na które chce podzielić dane;
- 2) inicjalizacja centroidów – wybiera się k punktów w przestrzeni danych jako początkowe centroidy – punkty reprezentujące środki klastrow – mogą być wybrane losowo lub za pomocą bardziej zaawansowanych metod;

¹⁰² platformy low-code to środowiska programistyczne umożliwiające tworzenie aplikacji za pomocą minimalnego kodowania, co znacznie skraca czas potrzebny na wdrożenie rozwiązań technologicznych. Wykorzystują one wizualne narzędzia projektowe, które pozwalają na budowanie aplikacji przez użytkowników o ograniczonej wiedzy technicznej, eliminując potrzebę ręcznego pisania kodu na każdym etapie

¹⁰³ Malinowska K. (2022)

¹⁰⁴ <https://stanford.edu/~cpiech/cs221/handouts/kmeans.html>

- 3) przypisanie punktów do centroidów – każdy punkt danych jest przypisany do najbliższej centroidy, tworząc k klastrów;
- 4) aktualizacja centroidów – dla każdego klastra oblicza się nowy centroid jako średnią wszystkich punktów przypisanych do tego klastra;
- 5) iteracja – kroki 3 i 4 są powtarzane, aż centroidy przestaną się zmieniać znacząco (lub osiągnięta zostanie maksymalna liczba iteracji).

K-Means może być używany do grupowania kierowców na podstawie różnych cech ich zachowania. Oto najprostszy przykład dla analizy wybranych metryk:

- histogram prędkości,
- histogram przyspieszeń,
- histogram hamowań,
- ilości zarejestrowanych gwałtownych manewrów (na 100 km),
- średnia prędkość dla jazdy w dzień / w nocy, dla teren zabudowany / niezabudowany,
- średnia prędkość dla różnych rodzajów dróg.

Zalety:

- K-Means jest stosunkowo prosty i szybki w implementacji, szczególnie przy małych i średnich zbiorach danych,
- dobrze skaluje się do dużych zbiorów danych,
- skutecznie grupuje dane w określoną liczbę klastrów,
- może pracować w wielu wymiarach (na wielu cechach).

Wady:


- należy z góry określić liczbę klastrów k, co może być trudne bez wcześniejszej wiedzy o danych,
- wyniki mogą różnić się w zależności od punktów początkowych centroidów, co może prowadzić do lokalnych minimów,
- zakłada, że klastry są sferyczne i mają podobną wielkość, co może nie odpowiadać rzeczywistym danym,
- algorytm klasteryzacji nie przypisuje etykiet dla danego zbioru danych (można próbować to zrobić niezależnie).

Kluczowy jest wybór liczby klastrów – można użyć metody "łokcia" (Elbow Method¹⁰⁵), która polega na:

¹⁰⁵ [https://en.wikipedia.org/wiki/Elbow_method_\(clustering\)](https://en.wikipedia.org/wiki/Elbow_method_(clustering))

- uruchomieniu K-Means dla różnych wartości k (np. od 1 do 10),
- obliczeniu wskaźnika sumy kwadratów odległości wewnątrz klastrow (Within-Cluster Sum of Squares, WCSS),
- narysowaniu wykresu WCSS w zależności od liczby klastrow k ,
- znalezieniu punktu, w którym spadek WCSS zaczyna być mniej stromy (tzw. "łokiec"). Ten punkt sugeruje optymalną liczbę klastrow.

Dane dwuwymiarowe (2 cechy): Algorytm K-Means przetwarza dane szybko, a wizualizacja jest prosta. Metoda daje przykładowy rezultat, jak na rys. 2. Oczywiście w przypadku analizy pod kątem profilowania stylu jazdy mamy znaczną liczbę metryk, a więc musimy obliczenia przeprowadzać w wielu wymiarach.



Rys. 2. Przykładowy wynik klasteryzacji zbioru danych algorytmem K-Means w dwóch wymiarach po 13 iteracjach (źródło: Wikipedia https://en.wikipedia.org/wiki/K-means_clustering)

W klasteryzacji tą metodą liczba wymiarów danych, teoretycznie jest nieograniczona. Można uwzględnić dowolną liczbę cech opisujących obiekty, które mają być grupowane. Jednakże, w praktyce istnieją pewne ograniczenia i wyzwania związane z dużą liczbą cech.

Wysoki wymiar danych (Curse of Dimensionality) oznacza dużą liczbę cech >100 . Im więcej cech, tym bardziej przestrzeń danych staje się "rozrzedzona", co może utrudniać znalezienie sensownych klastrow. W konsekwencji wysoki wymiar danych może prowadzić do problemów z interpretacją wyników i zmniejszenia efektywności algorytmów klasteryzacji.

Kolejnym problemem jest tutaj wzrost kosztów obliczeniowych. Złożoność obliczeniowa algorytmu K-Means rośnie liniowo z liczbą cech i liczbą punktów danych. Dla n punktów, k klastrów, c cech oraz i iteracji złożoność obliczeniowa wynosi $O(n \cdot k \cdot c \cdot i)$. Tak więc podwojenie ilości cech podwaja koszty obliczeń. Większa liczba cech oznacza większą ilość danych do przechowywania i przetwarzania, co zwiększa wymagania dotyczące pamięci.

Interpretację wyników trudno sobie wyobrazić dla więcej niż 3 wymiarów, czyli cech. Wizualizacja danych wielowymiarowych jest trudna, co utrudnia interpretację wyników klasteryzacji. Typowe techniki wizualizacji, takie jak PCA (Principal Component Analysis¹⁰⁶) czy t-SNE (t-Distributed Stochastic Neighbor Embedding¹⁰⁷), mogą pomóc w redukcji wymiarowości i wizualizacji danych.

Dane wielowymiarowe (>10 cech): Algorytm nadal jest efektywny, ale koszt obliczeniowy rośnie. Wizualizacja staje się trudniejsza.

Dane wysokowymiarowe (>100 cech): Zaczynają się pojawiać problemy związane z "curse of dimensionality". Konieczna jest redukcja wymiarowości lub selekcja cech.

Z powyższych względów starano się zredukować ilość cech, czyli metryk, trzymając się w obszarze wielowymiarowych (kilkanaście metryk), aby nie pogrążyć się w problemach charakterystycznych dla danych wysokowymiarowych.

Dane zebrane w pilotażu z udziałem ok. 50 aut, z których zbierano dane z trakerów przez okres 12 miesięcy, poddano klasteryzacji. Dobór liczby k metodą Elbow Method wskazuje, że optymalna liczba klastrów wynosi $k = 4$. Jest to zgodne z hipotezą roboczą podziału na style jazdy opisanym powyżej (Nieuważny / Ryzykowny / Agresywny / Taktyczny).

Interpretacja danych wskazuje jednak na inny charakter tego podziału. Nie do końca uzyskuje się rozgraniczenie pomiędzy stylami **Ryzykowny i Agresywny**, ponieważ zbyt wiele cech jest podobnych.

Osiągnięte wyniki raczej sugerują podział na zbiory, którym można przypisać poniższe etykiety stylu jazdy, poczynając od najbardziej pożądanego profilu kierowcy, do najmniej pożądanego:

- Taktyczny,
- Umiarkowany,

¹⁰⁶ https://en.wikipedia.org/wiki/Principal_component_analysis

¹⁰⁷ https://en.wikipedia.org/wiki/T-distributed_stochastic_neighbor_embedding

- Nieuważny,
- Ryzykowny lub Agresywny.

Uzyskaną klasteryzację nazwano od pierwszych liter jako **T/U/N/RA**.

Jak można zauważyć, pojawiła się grupa odpowiadająca stylowi jazdy, który nazwano „umiarkowany”, zdefiniowana jako dopełnienie pozostałych klastrów.

Omawiana metoda ze względu na jej prostotę i skuteczność, została zaimplementowana w prototypie rozwiązania i przyjęta jako wiodący mechanizm profilowania.

Poniżej opisano alternatywne metody, które mogłyby się sprawdzić. Zadaniem pracy nie jest jednak znalezienie optymalnej metody, ale wykazanie, że możliwe jest skuteczne wykorzystanie danych telemetrycznych w taryfikacji.

Podsumowanie rozdziału IV udowadnia, że skuteczne jest wykorzystanie łańcucha przetwarzania danych telemetrycznych łącznie z profilowaniem stylu jazdy kierowców.

Zastosowanie alternatywnych, bardziej zaawansowanych metod, może być bardziej optymalne i skuteczne. Poniżej zestawiono najbardziej rokujące metody uczenia maszynowego i ich krótki przegląd, z zaznaczeniem, że nie podjęto próby ich implementacji, ale dla całokształtu zagadnienia było potrzebne ich przeanalizowanie i zrozumienie.

— **Klasteryzacja hierarchiczna (Hierarchical Clustering)**¹⁰⁸

Metoda umożliwia tworzenie hierarchicznych grup kierowców na podstawie większej ilości cech, co może być przydatne w analizie bardziej złożonych wzorców zachowań.

Klasteryzacja hierarchiczna może być przeprowadzona na dwa sposoby:

- 1) aglomeracyjnie (łączenie),
- 2) dywizyjnie (dzielenie).

Klasteryzacja aglomeracyjna (łączenie) rozpoczyna się od traktowania każdego obiektu (kierowcy) jako osobnego klastra i łączy najbliższe pary klastrów na kolejnych etapach, aż do momentu, gdy wszystkie obiekty będą znajdować się w jednym klastrze. Kroki są następujące:

1. oblicz odległość między wszystkimi parami obiektów,
2. znajdź dwie najbliższe jednostki i połącz je, tworząc nowy klaster,

¹⁰⁸ https://en.wikipedia.org/wiki/Hierarchical_clustering

3. zaktualizuj macierz odległości, obliczając odległość między nowym klastrem a pozostałymi klastrami,
4. powtarzaj kroki 2-3, aż wszystkie obiekty zostaną połączone w jeden klaster.

Klasteryzacja dywizyjna (dzielenie) rozpoczyna się od jednego dużego klastra zawierającego wszystkie obiekty i dzieli go na mniejsze klastry na kolejnych etapach, aż każdy obiekt stanie się oddzielnym klastrem. Kroki są bardzo podobne:

1. rozpocznij od jednego klastra zawierającego wszystkie obiekty,
2. podziel klaster na dwa nowe klastry na podstawie kryterium maksymalnej odległości,
3. zaktualizuj macierz odległości,
4. powtarzaj kroki 2-3, aż każdy obiekt stanie się oddzielnym klastrem.

Klasteryzacja hierarchiczna może być używana do tworzenia hierarchicznych grup kierowców na podstawie różnych cech. Zaczynamy od każdego kierowcy jako osobnego klastra i stopniowo łączymy kierowców, którzy mają podobne zachowania, aż powstanie drzewo (dendrogram) reprezentujące hierarchię grup. Na dendrogramie możemy zobaczyć, w jakiej kolejności kierowcy są łączeni w grupy i na jakim poziomie podobieństwa.


Zalety:

- klasteryzacja hierarchiczna nie wymaga wcześniejszego określenia liczby klastrów, co jest konieczne w przypadku takich metod jak K-means,
- dendrogram daje wizualne przedstawienie hierarchii grup, co ułatwia interpretację wyników. Przykład dendrogramu zaprezentowano na rys. 3.

Wady:

- słaba skalowalność – klasteryzacja hierarchiczna może być obliczeniowo kosztowna przy dużych zestawach danych,
- wrażliwość na szum – może być wrażliwa na szum i outlier'y w danych.

Klasteryzacja hierarchiczna jest potężnym narzędziem do analizy i profilowania zachowań kierowców, szczególnie, gdy chcemy zrozumieć złożone wzorce i hierarchie w danych.



Rys. 3. Przykładowy dendrogram zbioru danych po klasteryzacji hierarchicznej (źródło: Wikipedia https://en.wikipedia.org/wiki/Hierarchical_clustering#/media/File:Iris_dendrogram.png)

— Algorytmy klasyfikacyjne Random Forest¹⁰⁹

Random Forest to metoda uczenia maszynowego, która może być stosowana zarówno do klasyfikacji, jak i regresji. W naszym wypadku interesuje nas klasyfikacja cech.

Metoda opiera się na agregacji wielu drzew decyzyjnych (Decision Tree¹¹⁰), aby uzyskać bardziej dokładne i stabilne przewidywania. Random Forest składa się z wielu drzew decyzyjnych, które działają jako zespół (ensemble).

Oto jak metoda działa krok po kroku:

1. losowanie bootstrapowe (Bootstrap Method¹¹¹) – z oryginalnego zbioru danych losowane są próbki (z powtórzeniami) do stworzenia różnych podzbiorów danych; każde drzewo decyzyjne w lesie jest trenowane na innym podzbiorze danych;
2. budowa drzew decyzyjnych – każde drzewo jest budowane przy użyciu losowo wybranej części cech (feature subset) na każdym węźle drzewa, co oznacza, że nie wszystkie cechy są rozważane na każdym podziale węzła, wprowadzając dodatkową różnorodność wśród drzew;
3. agregacja wyników – dla problemów klasyfikacyjnych, każde z drzew głosuje na klasę, a klasa z największą liczbą głosów staje się przewidywaną klasą (majority

¹⁰⁹ https://en.wikipedia.org/wiki/Random_forest

¹¹⁰ https://en.wikipedia.org/wiki/Decision_tree

¹¹¹ [https://en.wikipedia.org/wiki/Bootstrapping_\(statistics\)](https://en.wikipedia.org/wiki/Bootstrapping_(statistics))

voting); dla problemów regresyjnych, wyniki z poszczególnych drzew są uśredniane.

Klasyfikacja umożliwi nam – podobnie jak w poprzednich metodach – określić styl jazdy kierowców (np. ostrożny, umiarkowany, agresywny) na podstawie ich cech zachowań (reprezentowanych przez metryki).

Zalety:

- wysoka dokładność: dzięki agregacji wielu drzew decyzyjnych, Random Forest często przewyższa wcześniejsze metody pod względem dokładności,
- odporność na przeuczenie: losowanie cech i bootstrapowanie wprowadzają różnorodność, co zmniejsza ryzyko przeuczenia modelu,
- radzenie sobie z brakującymi danymi: Random Forest dobrze radzi sobie z brakującymi danymi i może używać średnich wartości lub innych technik wypełniania braków,
- obsługa dużej liczby cech: może pracować z dużą liczbą cech, nawet jeśli nie wszystkie cechy są istotne.

Wady:

- złożoność obliczeniowa: trening dużego zestawu drzew może być czasochłonny i wymagać dużych zasobów obliczeniowych, zwłaszcza przy dużych zbiorach danych,
- interpretowalność: chociaż pojedyncze drzewo decyzyjne jest łatwe do interpretacji, zestaw wielu drzew (las) staje się mniej przejrzysty i trudno jest ocenić istotności cech.

— **Support Vector Machines (SVM)**¹¹²

Support Vector Machine (SVM) to popularna metoda nadzorowanego uczenia maszynowego, używana zarówno do klasyfikacji, jak i regresji. Jest szczególnie skuteczna w problemach klasyfikacyjnych, gdzie celem jest znalezienie optymalnej wielowymiarowej hiperpowierzchni, która tworzy granicę między różnymi klasami danych.

W tym punkcie należy wyjaśnić co to jest uczenie nadzorowane (Supervised Learning¹¹³) to jedna z głównych gałęzi uczenia maszynowego, w której model jest trenowany na oznaczonych danych. Wymagane jest, żeby dla każdego przykładu w zbiorze treningowym były dostępne zarówno dane wejściowe (cechy), jak i

¹¹² https://en.wikipedia.org/wiki/Support_vector_machine

¹¹³ https://en.wikipedia.org/wiki/Supervised_learning

odpowiadające im poprawne wyniki (etykiety). Celem uczenia nadzorowanego jest nauczenie modelu przewidywania poprawnych wyników – w naszym wypadku klasyfikowania - na podstawie danych wejściowych.

Kluczowe elementy uczenia nadzorowanego to:

- zbiór treningowy (Training Set) – zbiór danych, który zawiera przykłady wejściowe oraz odpowiadające im poprawne wyniki; przykłady te są używane do trenowania modelu,
- funkcja celu (Loss Function) – metryka, który ocenia, jak dobrze model przewiduje wyniki na podstawie danych wejściowych; funkcja celu jest używana do optymalizacji modelu poprzez minimalizację błędu predykcji,
- algorytm uczenia (Learning Algorithm) – procedura, która przekształca zbiór treningowy i funkcję celu w wytrenowany model; algorytm uczenia dostosowuje parametry modelu w celu minimalizacji błędu predykcji.

SVM działa na zasadzie znajdowania hiperpowierzchni (w przypadku problemu dwuwymiarowego jest to linia) w przestrzeni cech, która rozdziela różne klasy danych maksymalizując odległość między najbliższymi punktami danych (wektorami wsparcia) a hiperpowierzchnią.

SVM może być używane do klasyfikacji stylów jazdy kierowców na podstawie wielu różnych cech, czyli metryk. Konieczna jest realizacja następujących etapów budowy modelu:

1. Przygotowanie danych – ponieważ SVM jest metodą nadzorowaną, potrzebuje oznaczonych danych (etykiet) do treningu. W kontekście stylu jazdy kierowców, etykiety mogą obejmować wcześniej już rozważane style jazdy (taktyczny, umiarkowany, nieuważny, agresywny, ryzykowny). Etykiety te mogą być przypisane na podstawie wcześniejszych obserwacji, analiz ekspertów lub na podstawie reguł ustalonych w badaniu.
2. Trening modelu SVM – model SVM jest trenowany na oznaczonym zbiorze danych, gdzie cechy (np. średnia prędkość, liczba nagłych hamowań) są wejściami a etykiety klas (ostrożny, umiarkowany, agresywny, ryzykowny) są wyjściami.
3. Klasyfikacja nowych danych – po przetrenowaniu modelu SVM, można go użyć do klasyfikacji nowych kierowców na podstawie ich cech jazdy. Model przewiduje, do której klasy (ostrożny, umiarkowany, agresywny) należy dany kierowca.

Zalety:

- skuteczność: SVM jest skuteczny w przypadkach, gdy istnieje wyraźna granica między klasami,
- odporność na przeuczenie: dzięki użyciu wektorów wsparcia, SVM jest odporny na przeuczenie, zwłaszcza w przestrzeniach o wysokiej wymiarowości,
- elastyczność: SVM może używać różnych funkcji jądra (kernel functions), takich jak liniowe, wielomianowe, radialne funkcje bazowe (RBF), co pozwala na efektywne modelowanie nieliniowych relacji.

Wady:

- wydajność: SVM może być mniej wydajny przy bardzo dużych zbiorach danych, ponieważ czas treningu i pamięć obliczeniowa rosną wraz z liczbą próbek,
- wymaga oznaczonych danych: jako metoda nadzorowana, SVM wymaga oznaczonych danych treningowych, co może być kosztowne i czasochłonne w przypadku dużych zbiorów danych.

— Analiza szeregów czasowych

Metody analizy szeregów czasowych, takie jak np. w oparciu o Recurrent Neural Networks¹¹⁴ (RNN) mogą być bardzo skuteczne w klasyfikacji stylów jazdy kierowców na podstawie danych sekwencyjnych. W kontekście klasyfikacji, niezmiennym celem jest przypisanie etykiety do sekwencji danych opisujących zachowanie kierowcy czy styl jazdy kierowcy. Jest to metoda uczenia nadzorowanego, więc dane trzeba odpowiednio przygotować. Model RNN jest trenowany na przygotowanych sekwencjach danych.

Model RNN jest rekurencyjną siecią neuronową, której architektura modelu może obejmować:

1. warstwę wejściową – przyjmuje sekwencje danych wejściowych,
2. warstwy rekurencyjne – LSTM (Long Short-Term Memory¹¹⁵) lub GRU (Gated Recurrent Unit¹¹⁶) mogą być używane do przechowywania i przetwarzania informacji z sekwencji,
3. warstwę wyjściową – generuje prawdopodobieństwo dla każdej klasy stylu jazdy.

¹¹⁴ https://en.wikipedia.org/wiki/Recurrent_neural_network

¹¹⁵ https://en.wikipedia.org/wiki/Long_short-term_memory

¹¹⁶ https://en.wikipedia.org/wiki/Gated_recurrent_unit

Po przetrenowaniu modelu RNN, można go użyć do klasyfikacji stylu jazdy nowych (nieznanych) kierowców na podstawie sekwencji ich zachowań. Model przyjmuje sekwencje danych wejściowych i generuje przewidywania dotyczące stylu jazdy.

Zalety:

- analiza danych sekwencyjnych: RNN są idealne do analizy czasowych wzorców w danych jazdy,
- pamięć długoterminowa: LSTM i GRU pozwalają na skuteczne przechowywanie i wykorzystanie informacji z długich sekwencji,
- dynamiczna adaptacja: RNN mogą dostosowywać swoje przewidywania, w miarę jak nowe dane są wprowadzane, co jest korzystne w analizie rzeczywistego czasu.

Wady:

- wydajność obliczeniowa: trening RNN może być kosztowny pod względem obliczeń, zwłaszcza przy dużych zbiorach danych,
- złożoność modelu: modele RNN, szczególnie z warstwami LSTM lub GRU, mogą być złożone i trudne do trenowania.

— **Podejście hybrydowe**

Połączenie kilku metod, np. klasteryzacji z analizą szeregów czasowych, może dostarczyć bardziej dokładnych i kompleksowych wyników w profilowaniu zachowań kierowców. Podejście hybrydowe (Hybrid Approaches) w analizie danych to techniki, które łączą różne algorytmy lub metody w celu uzyskania lepszych wyników niż przy użyciu pojedynczej techniki. W kontekście analizy stylu jazdy kierowców, hybrydowe podejścia mogą integrować różne metody analizy danych, takie jak analiza geoprzestrzenna, uczenie maszynowe, klasteryzacja i techniki predykcyjne, aby uzyskać bardziej kompleksowe i dokładne wyniki.

Podejście to może odkryć całą gamę pozornie niezauważalnych kwestii, przykładowo dwa poniższe zjawiska:

1. Zmienność zachowań w czasie

Częstym zjawiskiem jest zmienność stylu jazdy w czasie. Może to wynikać z bardzo wielu czynników:

- kierowca inaczej zachowuje się w podróży służbowej jadąc sam na długim dystansie (np. agresywny), a inaczej jak wiezie w weekend całą rodzinę (np. umiarkowany), czy przy wyjeździe na wakacje (np. taktyczny),
- kierowca inaczej zachowuje się w określonym stanie emocjonalnym, zmęczenia, czy pod wpływem alkoholu.

W dłuższej skali czasu różnice w jakiś sposób mogą się zacierać poprzez uśrednienie, ale w różnych okresach możemy mieć inne wyniki profilowania.

2. Schematy zachowań

Zmienność zachowań w czasie może być pozorna. Może ona wynikać z faktu, że ten sam pojazd jest w różnych okresach prowadzony przez różne osoby. Wykrywanie różnych kierowców prowadzących ten sam pojazd poprzez wykrywanie pewnych charakterystycznych wzorców (Pattern Recognition¹¹⁷) można osiągnąć za pomocą różnych metod w podejściu hybrydowym. Pozwala na bardziej dokładną identyfikację kierowców, co jest kluczowe w kontekście bezpieczeństwa, zarządzania flotą i personalizacji stawek ubezpieczeniowych.

Warto więc sprawdzać powyższe aspekty używając różnych metod w podejściu hybrydowym.

W rozdziale drugim zrealizowano cel poznawczy, analizując rozwój nowoczesnych technologii, takich jak IoT, AI, telematyka i uczenie maszynowe, oraz ich potencjalny wpływ na proces taryfikacji składek. Przedstawiono, w jaki sposób te technologie mogą być zastosowane do bardziej precyzyjnego określania ryzyka, co stanowi teoretyczne podstawy nowej metody. Omówiono również zagadnienia związane z profilem kierowcy oraz kwestię personalizacji ofert, podkreślając, że nowe technologie umożliwiają dynamiczne monitorowanie zachowań kierowców, co pozwala na dokładniejsze przewidywanie ryzyka i lepsze zarządzanie portfelem ubezpieczeniowym.

¹¹⁷ https://en.wikipedia.org/wiki/Pattern_recognition

3. Metodyka prowadzonych badań

3.1. Metodyczna koncepcja badań naukowych – triangulacja metod jakościowych i ilościowych.

Triangulacja metod jakościowych i ilościowych w badaniach naukowych stanowi istotne narzędzie w naukach o zarządzaniu i jakości. Jej celem jest uzyskanie pełniejszego obrazu badanego zjawiska poprzez integrację różnych podejść badawczych, co pozwala na bardziej wszechstronne i wiarygodne wyniki¹¹⁸. Triangulacja odnosi się do stosowania różnych podejść badawczych w celu lepszego zrozumienia badanego zjawiska. W naukach społecznych, w tym zarządzaniu, może obejmować łączenie metod jakościowych i ilościowych, różnych teorii, źródeł danych czy perspektyw badawczych. Dzięki niej można zniwelować ograniczenia pojedynczego podejścia badawczego oraz zwiększyć wiarygodność uzyskanych wyników¹¹⁹.

W literaturze wyróżnia się kilka typów triangulacji:

- **Triangulacja danych:** wykorzystanie różnych źródeł danych w badaniu tego samego zjawiska¹²⁰,
- **Triangulacja badaczy:** zaangażowanie więcej niż jednego badacza w proces zbierania i analizy danych¹²¹,
- **Triangulacja teoretyczna:** zastosowanie więcej niż jednej teorii lub perspektywy teoretycznej w analizie¹²²,
- **Triangulacja metodologiczna:** łączenie metod jakościowych i ilościowych¹²³.

Triangulacja danych polega na łączeniu informacji pochodzących z różnych źródeł, aby uzyskać bardziej wszechstronny obraz badanego zjawiska. W kontekście prowadzonych badań przez autora pracy, dane telemetryczne pochodzące z urządzenia IoT (urządzenie monitorujące pojazd) zostały zestawione z tradycyjnymi danymi

¹¹⁸ Bugdol, M. (2014). Systemy zarządzania jakością w administracji publicznej. Wydawnictwo Difin, str. 47., Łapińska, J. (2020). Zrównoważony rozwój. Wydawnictwo Politechniki Gdańskiej, str. 88.

¹¹⁹ Czakon, W. (2014). Kryteria oceny rygoru metodologicznego badań w naukach o zarządzaniu. Organizacja i Kierowanie, 1(161), 51-62, Sułkowski, Ł. (2021). Epistemologia, metodologia i metody badań w naukach o zarządzaniu i jakości. Wydawnictwo Uniwersytetu Łódzkiego, str. 327.

¹²⁰ Szarucki, M. (2020). Historia i perspektywy nauk o zarządzaniu. Wydawnictwo Uniwersytetu Ekonomicznego w Krakowie, str. 60.

¹²¹ Czakon W. (2014), str. 53.

¹²² Dyduch, W. (2015). Innowacyjność strategiczna przedsiębiorstw XXI w. Studia Ekonomiczne. Zeszyty Naukowe Uniwersytetu Ekonomicznego w Katowicach, nr 222, str. 50

¹²³ Lisiński, M. (2021). Zarządzanie jakością w organizacjach usługowych. Wydawnictwo Uniwersytetu Ekonomicznego w Krakowie, str. 36.

ubezpieczeniowymi, co pozwoliło na porównanie wyników z różnych perspektyw. Taka metoda minimalizuje ryzyko błędów wynikających z ograniczeń pojedynczych źródeł danych i pozwala na bardziej precyzyjną analizę ryzyka.

Zastosowanie triangulacji danych było kluczowe w ocenie ryzyka ubezpieczeniowego oraz weryfikacji hipotez. Korzystanie z danych w czasie rzeczywistym, pochodzących z telemetrycznych sensorów, w połączeniu z danymi historycznymi, umożliwiło identyfikację różnic w zachowaniach kierowców i stworzenie bardziej precyzyjnych profili ryzyka. Taka integracja metod pozwalała na lepsze rozpoznanie nie tylko potencjalnych zagrożeń, ale także zachowań, które mogły przyczynić się do poprawy bezpieczeństwa na drogach.

Triangulacja danych może przyczynić się do zwiększenia wiarygodności badań, szczególnie w sytuacjach, gdy same dane jakościowe lub ilościowe mogłyby nie dostarczyć pełnego obrazu badanej rzeczywistości¹²⁴. W badaniach dotyczących ubezpieczeń, takie podejście pozwala na bardziej holistyczną analizę ryzyka oraz możliwości lepszego dostosowania składki ubezpieczeniowej do indywidualnych potrzeb klienta.

Zastosowanie triangulacji teoretycznej w badaniach nad innowacyjnością strategiczną w przedsiębiorstwach, umożliwia bardziej wszechstronne i kompleksowe analizy.

Triangulacja metodologiczna z kolei pozwala na zrównoważenie różnic między podejściami jakościowymi i ilościowymi, co jest kluczowe w badaniach nad efektywnością organizacyjną¹²⁵.

Triangulacja znajduje szerokie zastosowanie w naukach o zarządzaniu, gdzie łączy się metody ilościowe, takie jak analizy statystyczne, z metodami jakościowymi, jak wywiady czy obserwacje uczestniczące. Takie podejście pozwala na uzyskanie pełniejszego obrazu zjawisk organizacyjnych, które są złożone i wielowymiarowe¹²⁶. Triangulacja w badaniach jakościowych jest nie tylko narzędziem zwiększającym

¹²⁴ Denzin, N. K. (1978). *The Research Act: A Theoretical Introduction to Sociological Methods*. McGraw-Hill, str. 239-245.

¹²⁵ Tamże, str. 37.

¹²⁶ Czakon W. (2014), str. 54, Glinka, B., & Czakon, W. (2020). *Podstawy badań jakościowych*. Polskie Wydawnictwo Ekonomiczne, str. 20.

wiarygodność wyników, ale także sposobem na lepsze zrozumienie złożonych interakcji i procesów, co jest szczególnie istotne w kontekście zarządzania i jakości¹²⁷.

Metody jakościowe, takie jak studia przypadków, wywiady czy analiza treści są kluczowe w badaniach nad zarządzaniem, ponieważ pozwalają na uchwycenie złożonych procesów społecznych i organizacyjnych. Zastosowanie tych metod umożliwia głębsze zrozumienie motywacji, wartości oraz kultury organizacyjnej, które są trudne do zmierzenia za pomocą metod ilościowych¹²⁸.

Integracja metod jakościowych z ilościowymi pozwala na uzyskanie bardziej kompleksowego obrazu zjawisk, zwłaszcza w kontekście badań nad innowacyjnością i kulturą organizacyjną, gdzie subtelne aspekty ludzkiego zachowania i dynamiki grupowej odgrywają kluczową rolę. Metody ilościowe, takie jak analizy statystyczne, modelowanie matematyczne czy badania ankietowe, są niezbędne w testowaniu hipotez i uogólnianiu wyników na większe populacje. W badaniach nad zarządzaniem, są wykorzystywane do badania efektywności organizacyjnej, analizy procesów czy oceny wyników finansowych¹²⁹.

Połączenie metod ilościowych z jakościowymi zwiększa wiarygodność wyników i pozwala na uzyskanie bardziej holistycznych analiz, co jest szczególnie istotne w badaniach nad efektywnością organizacyjną.

Metody jakościowe i ilościowe mają swoje zalety i ograniczenia. Metody jakościowe pozwalają na eksplorację nowych zjawisk i są bardziej elastyczne, podczas gdy metody ilościowe oferują precyzyjność i możliwość uogólnienia wyników. Triangulacja metod pozwala na wykorzystanie mocnych stron obu podejść, minimalizując ich słabości.

Zastosowanie triangulacji w badaniach nad innowacyjnością i przedsiębiorczością pozwala na uzyskanie pełniejszego obrazu badanych zjawisk poprzez łączenie różnych metodologii. Takie podejście pomaga przezwyciężyć subiektywizm oraz ograniczenia związane z nadmiernym uogólnieniem.

W ramach badań prowadzonych w niniejszej pracy można wykorzystać metody ilościowe, takie jak ankiety mierzące poziom zadowolenia klientów z zakupionej polisy, w połączeniu z metodami jakościowymi, takimi jak wywiady pogłębione z klientami i np. dystrybutorami ubezpieczeń. Dzięki triangulacji możliwe jest uzyskanie pełniejszego

¹²⁷ Mazurek-Lopacińska, K., & Sobocińska, M. (2018). Triangulacja w badaniach jakościowych. *Prace Naukowe Uniwersytetu Ekonomicznego we Wrocławiu*, nr 525, 11-20.

¹²⁸ Dyduch W. (2015), str. 59, Szarucki M. (2020), str. 62.

¹²⁹ Glinka B, & Czakon W. (2020), str. 26.

obrazu czynników wpływających na satysfakcję klienta, takich jak percepcja wartości polisy, doświadczenia podczas procesu zakupu oraz poziom obsługi klienta¹³⁰.

Zastosowanie triangulacji metodologicznej pozwala na uzyskanie bardziej wiarygodnych i wszechstronnych wyników. Wyniki jakościowe dostarczają kontekstu i głębszego zrozumienia danych ilościowych, co umożliwia lepsze formułowanie rekomendacji praktycznych dla zarządzania¹³¹.

Triangulacja metodologiczna, poprzez integrację różnych podejść badawczych, znacząco zwiększa dokładność i wiarygodność wyników badawczych, co jest kluczowe w analizie złożonych i dynamicznie zmieniających się zjawisk organizacyjnych. Triangulacja metodologiczna wiąże się z pewnymi wyzwaniami, takimi jak trudności w integrowaniu danych z różnych źródeł oraz różnice w podejściu metodologicznym między badaniami ilościowymi i jakościowymi. Istnieje również ryzyko preferowania wyników z jednej z metod, co może wpływać na obiektywność wyników. Problemy związane z integracją różnych metodologii badawczych oraz konieczność zachowania obiektywności w analizie wyników stanowią istotne wyzwania, które wymagają wysokich kompetencji metodologicznych oraz wypracowania jasnych kryteriów oceny wiarygodności i spójności wyników.

Triangulacja jest czasochłonna i kosztowna, co stanowi jej główne ograniczenie. Dodatkowo, interpretacja złożonych danych z różnych źródeł wymaga wysokich kompetencji badacza i może prowadzić do trudności w jednoznacznej interpretacji wyników¹³².

Złożoność analizy wyników triangulacji może prowadzić do subiektywizmu w interpretacji danych, co wymaga stosowania przejrzystych i rygorystycznych procedur analizy, aby minimalizować ryzyko błędów badawczych.

Biorąc pod uwagę badania prowadzone w niniejszej pracy można stwierdzić, że zastosowanie nowoczesnych technologii w celu opracowania innowacyjnej metody taryfikacji składek ubezpieczeń komunikacyjnych, opartej na danych zbieranych w czasie rzeczywistym, wymaga przeprowadzenia intensywnych i wieloaspektowych badań, angażujących liczne obszary i wymagających ogromnego nakładu prac.

Krytyczne było sprawdzenie co najmniej poniższych aspektów:

¹³⁰ Mazurek-Lopacińska, K., & Sobocińska, M. (2018). Triangulacja w badaniach jakościowych. *Prace Naukowe Uniwersytetu Ekonomicznego we Wrocławiu*, nr 525, str. 18.

¹³¹ Lisiński M. (2021), str. 42.

¹³² Szarucki M. (2020), str. 70.

- realistyczność – sprawdzenie, czy dane technologie są dostępne i czy ich gotowość jest na wysokim stopniu rozwoju, umożliwiającym sproduktowanie rozwiązania,
- adekwatność – sprawdzenie, czy proponowane rozwiązania i metodyka adresuje postawione cele,
- użyteczność – przetestowanie, czy przykładowe proste prototypowe rozwiązania mogą generować zakładaną korzyść w stosunku do klasycznych rozwiązań.

Badanie tych aspektów przebiegało zarówno w płaszczyźnie czysto naukowej, jak i empirycznej, stąd zastosowanie triangulacji metod jakościowych i ilościowych do badania hipotezy było naturalnym wyborem. Korzystanie w procesie badawczym z różnych podejść i metod łączących obiektywne fakty naukowe i empiryczne wraz z subiektywnymi opiniami i ankietami, lepiej oddaje rzeczywistą złożoność zagadnienia, niż wąskie i wybiórcze zastosowanie pojedynczych metod.

W swoim badaniu autor starał się wybrać takie elementy tej metodyki, aby położyć akcenty głównie na:

- Zwiększenie rzetelności i trafności (czyli adresujemy „adekwatność” oraz „użyteczność”) – triangulacja umożliwia weryfikację wyników uzyskanych różnymi metodami, co zwiększa zaufanie do tychże wyników badań. Użycie różnych podejść pozwala na minimalizację błędów związanych z ograniczeniami pojedynczej metody.
- Komplementarność wyników (głównie adresujemy „adekwatność”) – metoda pozwala na uzyskanie wyników, które mogą się uzupełniać, co prowadzi do głębszego zrozumienia badanego problemu. W przypadku rozbieżności wyników między różnymi metodami, badacze mogą odkryć nowe aspekty zjawiska, które wcześniej mogły być pominięte.
- Praktyczne zastosowanie (fokus na „użyteczności”) – metoda pozwala na integrację danych ilościowych (np. z analizy danych, ankiet, badań sondażowych wpływu zastosowania rozwiązania) z danymi jakościowymi (np. z analizy rezultatów, wywiadów, obserwacji), co prowadzi do bardziej holistycznego podejścia do oceny.

W niniejszych badaniach wykorzystano cztery główne typy triangulacji, które wyróżnia Norman Denzin, czyli:

1. triangulacja danych – porównywano wyników uzyskanych z różnych źródeł danych, zarówno „twardych” danych pozyskanych dzięki teledziennemu, jak i wspomnianych danych ilościowo-jakościowych uzyskanych z ankiet, sondaży, analizy rezultatów, wywiadów, obserwacji;

2. triangulacja teorii – sprawdzano różne teorie (głównie algorytmy przetwarzania danych) do interpretacji tych samych danych, co pozwala na szersze zrozumienie natury danych; stworzony multidyscyplinarny zespół składający się ze specjalistów z zakresu ubezpieczeń, Data Science, ML/AI, telemetrii sprawdzał równoległe różne dostępne opracowania naukowe i rozwiązania;
3. triangulacja badaczy – zaangażowano wielu badaczy (w ramach zespołu wymienionego punkt wyżej) do prowadzenia tego samego badania, co pozwoliło na zminimalizowanie osobistych uprzedzeń, a dodatkowo niezależne eksperymenty i pilotaże przeprowadzone w różnych środowiskach, były analizowane i porównywane „krzyżowo” przez różnych specjalistów;
4. triangulacja metod – łączono nie tylko różne metody badawcze jakościowe i ilościowe w jednym badaniu, ale też różne metodyki analityczne w oparciu o statystykę, ML/AI czy też inne adekwatne podejścia, co pozwoliło na rzetelniejsze sprawdzenie postawionej hipotezy i ocenę potencjału proponowanych rozwiązań¹³³.

Podsumowując, triangulacja metod jakościowych i ilościowych odgrywa kluczową rolę w badaniach naukowych, szczególnie w naukach o zarządzaniu i jakości. Dzięki integracji różnych podejść badawczych triangulacja umożliwia uzyskanie bardziej wszechstronnych i wiarygodnych wyników, co jest szczególnie istotne w kontekście analiz złożonych i dynamicznych zjawisk organizacyjnych. Mimo, że triangulacja pozwala na zrównoważenie różnic między metodami jakościowymi i ilościowymi oraz dostarcza bogatego kontekstu interpretacyjnego, jej zastosowanie wiąże się również z wyzwaniami, takimi jak złożoność analizy, czasochłonność oraz ryzyko subiektywności w interpretacji wyników. Jednakże, w przypadku projektowania innowacyjnych rozwiązań technologicznych, takich jak opracowanie nowej metody taryfikacji składek ubezpieczeniowych, konieczne jest podejście, które nie tylko integruje różne metody badawcze, ale także umożliwia systematyczne projektowanie, wdrażanie i testowanie artefaktów w rzeczywistych warunkach.

¹³³ Norman Denzin: *Sociological Methods: A Sourcebook*. Aldine Transaction, 2006. ISBN 9780-202308401.

W tym kontekście metoda Design Science Research Process (DSRP) oferuje najbardziej adekwatne narzędzie badawcze. Poniżej przedstawiono fazy zgodne z metodyką DSRP, które podjęto tym celu:

- Identyfikacja problemu – na początku procesu DSRP, kluczowe jest zrozumienie problemu, poprzez zgromadzenie danych i ich wstępną analizę. W tym etapie zastosowano zarówno triangulację danych (zbierając zarówno dane jakościowe, ilościowe), jak i triangulację teorii (przeglądając różne podejścia do analizy danych).
- Projektowanie rozwiązania – w tej fazie, na podstawie zebranych informacji i założeń, sprawdzono wiele możliwości i stworzono prosty prototyp modelu taryfikacji, który uwzględnia zarówno tradycyjne czynniki (np. wiek kierowcy, historia ubezpieczeniowa), jak i dane z telematyki. W eksperymentowaniu i budowaniu prototypów wykorzystano triangulację metod.
- Ewaluacja rozwiązania – przeprowadzono testy zarówno jakościowe, jak i ilościowe (na bazie niezależnych pilotaży rozwiązania), aby ocenić użyteczność modelu taryfikacji. Tutaj przeplatają się wszystkie cztery typy triangulacji z podejścia TMJII. Szczególnie ważna okazała się triangulacja danych z pilotaży oraz triangulacja badaczy, czyli niezależne „krzyżowe” podejście do analizowania rezultatów (badacze biorący udział w danym eksperymencie, nie analizowali wyników tego eksperymentu, natomiast analizowali wyniki innych eksperymentów).

Warto podkreślić również, że DSRP podlegał iteracyjnemu procesowi samodoskonalenia. Dział B+R (Badania i Rozwój) realizujący prototyp, swoją organizację pracy oparł o SCRUM¹³⁴, który z natury rzeczy jest procesem iteracyjnym, a fundamentem jest przeprowadzenie na końcu każdego cyklu rewizji (Sprint Review¹³⁵) oraz retrospekcji (Sprint Retrospective¹³⁶). Przyjęty framework pracy oparty SCRUM okazał się skuteczną metodą wspierania DSRP.

DSRP, dzięki swojemu iteracyjnemu charakterowi, pozwala na ciągłe doskonalenie rozwiązań poprzez cykliczne testowanie i ewaluację, co jest kluczowe dla osiągnięcia praktycznych i zrównoważonych wyników. Ponadto, DSRP umożliwia nie tylko teoretyczne zrozumienie zjawisk, ale także ich praktyczne zastosowanie, co jest

¹³⁴ <https://www.scrum.org/resources/what-scrum-module>

¹³⁵ <https://www.scrum.org/resources/what-is-a-sprint-review>

¹³⁶ <https://www.scrum.org/resources/what-is-a-sprint-retrospective>

niezwykle ważne w badaniach nad nowoczesnymi technologiami i ich wdrożeniem w praktyce biznesowej.

Dlatego, choć triangulacja metodologiczna stanowi cenne narzędzie w badaniach naukowych, wybór DSRP w niniejszych badaniach był podyktowany potrzebą stworzenia efektywnego modelu badawczego, który nie tylko uwzględnia różnorodne aspekty teoretyczne i metodologiczne, ale także umożliwia rozwój i wdrożenie innowacyjnych rozwiązań technologicznych, odpowiadających na wyzwania współczesnego zarządzania ryzykiem ubezpieczeniowym. Szerzej wykorzystanie metodyki DSRP w badaniach prowadzonych w ramach niniejszej rozprawy przedstawiono w kolejnym podrozdziale.

3.2. Metodyczna koncepcja badań empirycznych – metodyka Design Science Research Process

Design Science Research Process (DSRP) jest metodologią badawczą skoncentrowaną na projektowaniu i ocenie artefaktów mających na celu rozwiązywanie złożonych problemów organizacyjnych. W przeciwieństwie do tradycyjnych metod badawczych, które skupiają się na opisie i wyjaśnianiu zjawisk, DSRP koncentruje się na tworzeniu innowacyjnych rozwiązań, które są testowane i udoskonalane w procesie iteracyjnym.

Metodologia DSRP została szczegółowo opisana przez Hevnera, Marcha, Parka i Rama w ich przełomowej pracy z 2004 roku, która zdefiniowała podstawy tej metodologii w kontekście badań informatycznych i nauk o zarządzaniu. Kluczowym elementem DSRP jest iteracyjny cykl badawczy, obejmujący projektowanie, wdrażanie, testowanie i ewaluację artefaktów. Proces ten pozwala na ciągłe doskonalenie rozwiązań w odpowiedzi na zmieniające się wymagania i wyniki testów empirycznych¹³⁷.

W literaturze przedmiotu podkreśla się, że DSRP jest metodologią ściśle związaną z praktyką, łączącą teorię z aplikacjami praktycznymi, co jest kluczowe dla tworzenia rozwiązań, które są zarówno innowacyjne, jak i efektywne¹³⁸. W kontekście badań nad taryfikacją i kwotacją składek ubezpieczeniowych, metodologia ta okazała się idealnym

¹³⁷ Hevner, A. R., March, S. T., Park, J., & Ram, S. (2004). Design Science in Information Systems Research. *MIS Quarterly*, 28(1), 75-105.

¹³⁸ March, S. T., & Smith, G. F. (1995). Design and natural science research on information technology. *Decision Support Systems*, 15(4), 251-266.

wyborem, umożliwiając dynamiczne modelowanie taryfikacji, które jest bardziej elastyczne i precyzyjne niż tradycyjne podejścia.

DSRP zostało zastosowane w badaniu jako narzędzie do opracowania nowej metody taryfikacji i kwotacji składek ubezpieczeniowych, opierającej się na dynamicznym modelowaniu ryzyka ubezpieczeniowego za pomocą modułu komunikacji zdalnej. Proces ten rozpoczął się od zdefiniowania problemu badawczego, polegającego na potrzebie stworzenia bardziej elastycznego i dokładnego modelu taryfikacji, dostosowującego się do bieżących danych dotyczących zachowań kierowców i warunków eksploatacji pojazdów¹³⁹.

Kolejne iteracje procesu obejmowały projektowanie i testowanie różnych prototypów systemu, które następnie były oceniane na podstawie zebranych danych empirycznych. Wyniki testów były wykorzystywane do dalszego doskonalenia systemu, co pozwoliło na stworzenie metody taryfikacji, która lepiej odpowiada na potrzeby rynku ubezpieczeniowego.

Zastosowanie podejścia Design Science Research Process (DSRP) w badaniach nad nowoczesnymi systemami taryfikacji składek ubezpieczeniowych umożliwiło dynamiczne dostosowywanie taryfikacji na podstawie rzeczywistych danych telemetrycznych, co zwiększyło precyzję oceny ryzyka i dopasowanie ofert ubezpieczeniowych do potrzeb klientów. Kluczowym elementem tej metody było wykorzystanie algorytmów sztucznej inteligencji (AI) oraz technik uczenia maszynowego (ML), które pozwoliły na bieżącą analizę danych i dokładniejsze modelowanie ryzyka. Zastosowanie inteligentnych systemów wspomagania decyzji oparte na AI umożliwiło szybsze i precyzyjniejsze przetwarzanie danych, co przyczyniło się do znacznej poprawy w procesie podejmowania decyzji dotyczących oceny ryzyka i kwotacji składek ubezpieczeniowych¹⁴⁰. Przeprowadzona analiza opierała się na modelach inteligentnych systemów wspomagania decyzji, które wykorzystują techniki AI do dynamicznego przetwarzania danych i podejmowania decyzji w czasie rzeczywistym¹⁴¹. Kluczowym elementem DSRP jest iteracyjny cykl projektowania i

¹³⁹ Peffers, K., Tuunanen, T., Rothenberger, M. A., & Chatterjee, S. (2007). A design science research methodology for information systems research. *Journal of Management Information Systems*, 24(3), 45-77.

¹⁴⁰ Hernes, M., Golec, P., Sajewski, T., Walaszczyk, E., & Rot, A. (2023). Prediction of customer purchases using LSTM deep neural network. In *Lecture Notes in Networks and Systems* (Vol. XX).

¹⁴¹ Hernes, M., & Wątróbski, J. (2024). Emerging challenges in intelligent management information systems. In *Proceedings of the ECAI 2023 Conference*.

testowania artefaktów¹⁴². W badaniu tym proces ten polegał na ciągłym doskonaleniu metody taryfikacji i kwotacji składek ubezpieczeniowych, z uwzględnieniem zmieniających się danych empirycznych oraz wyników testów prototypowych rozwiązań.

Projektowanie rozpoczęło się od identyfikacji kluczowych wymagań, jakie miała spełniać nowa metoda taryfikacji, z naciskiem na dynamiczne modelowanie ryzyka ubezpieczeniowego i integrację z systemami telematycznymi. Prototypy były następnie testowane w warunkach rzeczywistych, co pozwoliło na identyfikację mocnych stron oraz obszarów wymagających dalszego doskonalenia. Każda iteracja cyklu DSRP obejmowała testowanie prototypów z udziałem użytkowników reprezentujących docelowych klientów ubezpieczyciela. Dane zebrane podczas testów były analizowane, a wyniki ewaluacji służyły jako podstawa do wprowadzania kolejnych ulepszeń w projektowanym systemie. Weryfikacja skuteczności artefaktów projektowanych w ramach DSRP opierała się na serii metryk, które pozwalały na ocenę ich efektywności w kontekście rzeczywistych zastosowań.

Do kluczowych metryk należały:

- dokładność taryfikacji: mierzona na podstawie zgodności wyników taryfikacji z rzeczywistymi danymi dotyczącymi ryzyka ubezpieczeniowego,
- elastyczność systemu: oceniana na podstawie zdolności systemu do dostosowywania taryfikacji w czasie rzeczywistym, w odpowiedzi na zmieniające się warunki,
- integracja z modułami telematycznymi: mierzona na podstawie zdolności systemu do zbierania i przetwarzania danych z różnych źródeł telematycznych.

W tym rozdziale zastosowano podejście metodologiczne oparte na triangulacji danych oraz Design Science Research Process (DRSP), które umożliwiło pełne przeprowadzenie badań nad nową metodą taryfikacji. DRSP pozwoliło na iteracyjne projektowanie i testowanie prototypów systemu taryfikacji, co było kluczowe dla oceny skuteczności zaproponowanych rozwiązań. Łączenie triangulacji danych z podejściem DRSP umożliwiło uzyskanie zarówno głębokiego zrozumienia zjawisk, jak i dynamicznego dostosowywania metody do zmieniających się warunków rynkowych i technologicznych. W efekcie, nowa metoda taryfikacji, oparta na danych telemetrycznych i algorytmach AI, znacząco poprawiła precyzję oceny ryzyka ubezpieczeniowego, spełniając założone cele badawcze.

¹⁴² Pańkowska, M. (2019). Zastosowanie paradygmatu Hevnera w projektowaniu innowacyjnych rozwiązań informatycznych. Zeszyty Naukowe Uniwersytetu Ekonomicznego w Katowicach.

4. Nowa metoda taryfikacji i kwotacji składki w ubezpieczeniach komunikacyjnych w zakładach ubezpieczeń

4.1. Założenia metody taryfikacji i kwotacji składki

Proponowana metoda taryfikacji opiera się na rzeczywistych danych telemetrycznych, pochodzących bezpośrednio z pojazdów ubezpieczonych dzięki zastosowaniu urządzeń internetu rzeczy (IoT), umożliwiających stałe monitorowanie parametrów związanych z eksploatacją pojazdu oraz stylem jazdy. Zebrane dane są następnie analizowane przez zaawansowane algorytmy sztucznej inteligencji (AI) oraz techniki uczenia maszynowego (ML), co pozwala na tworzenie dokładnych profili ryzyka dla indywidualnych użytkowników.

W porównaniu do tradycyjnych metod opartych na danych statycznych, nowa metoda taryfikacji umożliwia bardziej dynamiczne i elastyczne podejście do kwotacji składek, które odzwierciedla rzeczywiste warunki użytkowania pojazdów.

Jednym z kluczowych elementów proponowanej metody taryfikacji jest możliwość precyzyjnej oceny ryzyka na podstawie danych telemetrycznych, zbieranych w czasie rzeczywistym. Dzięki zastosowanemu rozwiązaniu, które rejestrują szczegółowe informacje dotyczące parametrów eksploatacyjnych pojazdu, takich jak prędkość, przyspieszenie, hamowanie, a także warunki drogowe, możliwe jest dokładne modelowanie stylu jazdy każdego użytkownika. Zastosowanie algorytmów AI i ML pozwala na tworzenie dynamicznych profili użytkowników, które są nie tylko dokładniejsze od danych demograficznych czy historycznych, ale również zmieniają się w zależności od bieżącego stylu jazdy. Dzięki temu możliwe jest precyzyjne określenie składek ubezpieczeniowych na podstawie rzeczywistych zachowań kierowcy, co eliminuje problem niedopasowania taryfikacji do faktycznego poziomu ryzyka. Proponowana metoda oferuje zatem znacznie większą elastyczność w porównaniu do statycznych taryfikacji, które opierają się na prognozach historycznych.

Pamiętać należy, że oczekiwania zakładów ubezpieczeń, zwłaszcza w zakresie wprowadzenia nowych metod taryfikacji, często sprowadzają się do prostych i tanich rozwiązań technologicznych. Zakłady ubezpieczeń preferują technologie oparte na aplikacjach mobilnych, które są łatwe do wdrożenia i niewymagające dużych nakładów finansowych.

Takie rozwiązania, jak aplikacje monitorujące styl jazdy, np. Yanosik, były testowane przez czołowych ubezpieczycieli, jednak nie zakończyły się pełnym wdrożeniem

operacyjnym¹⁴³. Główną przeszkodą w tym przypadku była tendencja użytkowników do celowego dostosowywania swojego stylu jazdy na czas testów, co skutkowało zafałszowanymi danymi. Po zakończeniu testów kierowcy często wracali do swoich wcześniejszych nawyków, co sprawiało, że zebrane dane nie oddawały realnego poziomu ryzyka z uwagi na generowaną szkodowość po zakończeniu eksperymentu przez jego uczestników.

W przypadku aplikacji mobilnych dodatkowym wyzwaniem jest konieczność określonej aktywności użytkownika, np. manualnego uruchamiania aplikacji. Tego typu rozwiązania są podatne na błędy ludzkie i nie zapewniają stałego monitorowania pojazdu.

W przeciwieństwie do nich, w ramach badań przeprowadzonych w niniejszej pracy opracowano urządzenie *Inssue Box*, które zostało zaprojektowane i przygotowane specjalnie na potrzeby tego badania. Urządzenie to działa niezależnie energetycznie, nie wymaga żadnej interakcji ze strony ubezpieczonego i nie można go zafałszować. Może być dyskretnie umieszczone w samochodzie, na przykład w schowku, co sprawia, że dostarczane dane są obiektywne i wiarygodne. *Inssue Box* oferuje więc znaczną przewagę nad aplikacjami mobilnymi, zapewniając precyzyjną ocenę ryzyka opartą na rzeczywistych danych z pojazdu.

Rozwiązania oparte na aplikacjach mobilnych są podatne na błędy ludzkie oraz intencjonalne manipulacje. Ubezpieczony, dążąc do uzyskania zniżek, może włączyć aplikację tylko w momentach, gdy planuje bezpieczną jazdę, a w sytuacjach, w których nie przestrzega przepisów drogowych, może ją wyłączyć. To ogranicza możliwość uzyskania rzetelnych danych o stylu jazdy, prowadząc do nieprawidłowej oceny ryzyka przez zakład ubezpieczeń. W przeciwieństwie do tego, rozwiązanie *Inssue Box* zapewnia niezależny od użytkownika monitoring pojazdu, co eliminuje możliwość manipulacji danymi.

Z perspektywy ubezpieczonych, ich oczekiwania zazwyczaj skupiają się na minimalnym zaangażowaniu i współpracy z ubezpieczycielem. Ubezpieczeni często preferują rozwiązania, które nie wymagają zbyt dużej ingerencji w ich codzienne życie ani udostępniania szczegółowych danych. Obawy dotyczące utraty prywatności sprawiają, że wielu klientów niechętnie dzieli się szczegółowymi informacjami o swoim stylu jazdy czy lokalizacji pojazdu. To z kolei ogranicza możliwości precyzyjnej oceny

¹⁴³ <https://payhowyudrive.pl/>

ryzyka i personalizacji ofert ubezpieczeniowych, co stanowi wyzwanie dla wprowadzenia nowych technologii w proces taryfikacji i kwotacji składek.

Zakłada się, że opracowana w niniejszej rozprawie metoda, opisana w dalszej części rozdziału, umożliwi precyzyjną ocenę ryzyka dzięki wykorzystaniu zaawansowanych danych telemetrycznych zbieranych w czasie rzeczywistym przez urządzenie *Inssue Box*. W przeciwieństwie do rozwiązań opartych na aplikacjach mobilnych, *Inssue Box* zapewnia stały i niezależny monitoring pojazdu, co eliminuje ryzyko manipulacji danymi ze strony ubezpieczonych. Urządzenie to rejestruje nie tylko podstawowe parametry, takie jak prędkość, ale również szczegółowe informacje o warunkach jazdy, intensywności hamowania, przyspieszeniach, a nawet stylu pokonywania zakrętów. Dzięki temu możliwe jest stworzenie kompleksowego profilu kierowcy, który odzwierciedla jego rzeczywisty poziom ryzyka, a nie jedynie chwilowe, kontrolowane zachowania.

Opracowana metoda pozwala również na dynamiczną analizę stylu jazdy, uwzględniającą zmieniające się warunki drogowe oraz nawyki kierowcy w dłuższym okresie. Takie podejście gwarantuje, że taryfikacja i kwotacja składek będą dokładniej odzwierciedlać indywidualne zachowania ubezpieczonych, prowadząc do bardziej sprawiedliwej i efektywnej oceny ryzyka. W rezultacie, proponowana metoda staje się innowacyjnym rozwiązaniem, które odpowiada na wyzwania współczesnego rynku ubezpieczeń, łącząc precyzyjną analizę danych telemetrycznych z elastycznością i obiektywnością, jakiej nie oferują tradycyjne narzędzia oceny ryzyka. W celu zwiększenia precyzji oceny ryzyka i jeszcze lepszego dostosowania składek ubezpieczeniowych, w ramach niniejszych badań przyjęto założenie, że kluczowym elementem tej metody będzie analiza stylu jazdy kierowców, którą można opisać zestawem metryk odzwierciedlających ich zachowania na drodze.

W niniejszych badaniach przyjęto, że pojęcie stylu jazdy, który możemy opisać odpowiednim zestawem cech, wyliczonych w metrykach, może równie dobrze profilować kierowców i przypisać ich do odpowiedniego stylu jazdy. Przynależność do danego stylu jazdy determinuje sposób wyliczania ryzyka ubezpieczeniowego, a w konsekwencji przypisanie odpowiedniej stawki taryfikacyjnej.

Profile stylu jazdy kierowców zostały wypracowane w konsultacji z psychologiem transportu. Biorą one pod uwagę wiele aspektów, ale starano się ograniczyć liczbę profili – przyjęto założenie, że 4 główne profile stylu jazdy będą wystarczające:

1. kierowca „nieuważny”,

2. kierowca „ryzykowny”,
3. kierowca „agresywny”,
4. kierowca „taktyczny”.

Kierowca „nieuważny”

Niepełna koncentracja uwagi na prowadzeniu samochodu jest wynikiem albo wykonywaniem dodatkowych czynności manualnych albo zaangażowania mentalnego w sprawy niezwiązane z prowadzeniem samochodu. Również nadmierne pobudzenie emocjonalne wymaga przydzielenia części puli zasobów uwagi w regulację emocji, zamiast być w pełni wykorzystana do prowadzenia.

Wykonywanie dodatkowych czynności sprawia, że system poznawczy musi poradzić sobie z trudniejszym zadaniem niż gdyby kierowca był w pełni skupiony na drodze. Wykonywanie dodatkowego zadania obniża sprawność kierowcy, ponieważ pula zasobów uwagi wykorzystywana jest do wykonania nie jednego, a dwóch zadań.

W wyniku tego:

- rozproszenie uwagi znajduje odzwierciedlenie w zapisie telemetrycznym,
- dystraktory sprawiają, że prowadzenie samochodu jest dla systemu poznawczego trudniejsze.

Kierowca wprowadza tzw. Czynności kompensacyjne po to, aby poradzić sobie w tej sytuacji, przykładowo:

- zwalnia oraz zwiększa odległość od poprzedzającego samochodu,
- jazda charakteryzuje się dużą zmiennością prędkości,
- obserwujemy dużą zmienność odchylenia od linii centralnej, prowadzi po zmiennym torze jazdy,
- kierowca wykonuje duże kompensacyjne ruchy kierownicą zamiast małych podtrzymujących tor jazdy (brany jest pod uwagę kąt odchylenia kierownicy, liczba manewrów kierownicą, zmiana kierunku jazdy, regularność ruchów kierownicą),
- na dojeździe do skrzyżowania nieuważny kierowca przy małych prędkościach delikatnie uderza w pedał hamulca,
- kontrola przepustnicy jest szarpana, pedał gazu wielokrotnie jest niepotrzebnie wciskany i puszczany.

Kierowca „ryzykowny”

Osoba ryzykowna uważa, że większość przepisów drogowych jest jedynie sugestią i ostatecznie to on podejmuje decyzję, czy zastosować się do nich czy nie. Ma skłonność

do przeceniania swoich możliwości jako kierowcy. Nie ma na celu skrzywdzić innych uczestników ruchu. Jego zachowania, jeśli mu się spieszy, mają następujący charakter:

- przekracza dozwoloną prędkość,
- przekracza znacznie prędkość przy wyprzedzaniu,
- nie dostosowuje prędkości do warunków pogodowych,
- wyprzedza „na trzeciego” oceniając, że zdąży i zmieści się przed nadjeżdżającym samochodem,
- na dojeździe do skrzyżowania ściga się z jadącym drugim pasem samochodem po to, aby ustawić się przed nim,
- wyprzedza pomimo zakazu,
- stara się zdążyć przed nadjeżdżającym tramwajem, podczas skrętu w lewo,
- jedzie zygzakiem pomiędzy zbyt wolno jadącymi samochodami.

Kierowca ryzykowny często prowadzi pod wpływem substancji psychoaktywnych oraz pod wpływem zmęczenia. Z psychologicznego punktu widzenia są to osoby, które mają wysokie zapotrzebowanie na stymulację z zewnątrz. Prowadzenie z nadmierną prędkością, wchodzenie ostro w zakręty lub prowadzenie pod wpływem alkoholu wprowadza ich w optymalny poziom pobudzenia. Podejmowanie ryzyka jest związane z odczuwaną przyjemnością. Czują się usatysfakcjonowani.

Kierowca „agresywny”

Agresja na drodze jest związana z gniewem, jaki kierowca przeżywa wskutek niesprzyjających okoliczności na drodze. Niebezpieczne zachowanie jest konsekwencją potrzeby regulacji nieprzyjemnych emocji. Ściganie, błyskanie światłami, blokowanie, zajeżdżanie drogi itp. mają na celu wyładowanie gniewu. Używa samochodu jako narzędzia do wymierzenia sprawiedliwości lub nauczania innych kierowców poprawnego zachowania. Zachowanie jest wymierzone w innych uczestników ruchu drogowego, w efekcie naraża ich na utratę zdrowia i życia.

W literaturze psychologicznej odróżnia się kierowców agresywnych od kierowców ryzykownych¹⁴⁴. Jednak rozróżnienie to zrobione jest ze względu na motywację, jaka uruchamia niebezpieczne zachowanie. Powstaje pytanie jak odróżnić ryzykowny styl jazdy od agresywnego stylu jazdy na poziomie danych telemetrycznych. Jest to o tyle

¹⁴⁴ Jonah, B. A. (1997). Personality and risky driving: The role of sensation seeking and aggressiveness. Risk-taking behavior and traffic safety, 81-106.
Shinar, D. (1998). Aggressive and risky driving: Psychosocial correlates and driver's characteristics. Transportation Research Part F: Traffic Psychology and Behaviour, 1(2), 137-160.

istotne, ponieważ przejeżdżanie np. na pomarańczowym świetle zaliczane jest raz do zachowań ryzykownych, raz do zachowań agresywnych¹⁴⁵.

Na poziomie danych telemetrycznych, zarówno zachowania agresywne, jak i ryzykowne są związane z gwałtownymi przyspieszeniem i hamowaniem. Zakłada się, że gwałtowne hamowanie przyjmuje wartość między -4.0 a -7,7 m/s². Jednak na podstawie tego wskaźnika trudno podjąć zdiagnozować przyczynę gwałtownego hamowania. Może to być wyraz braku antycypacji zdarzeń (nieuwagi) czy sytuacji konfliktowej (około wypadkowej). Używanie tego wskaźnika powinno być powiązane z dodatkowymi czynnikami. Płynności hamowania używa się jako wskaźnika uważnej jazdy, szczególnie na dojazdach na skrzyżowaniach. Jednak posługiwanie się tym wskaźnikiem w ustawianiu rankingu „dobrego kierowcy” naraża na niebezpieczeństwo wjeżdżania na skrzyżowanie na pomarańczowym świetle.

Aby odróżnić, czy gwałtowne hamowanie jest spowodowane sytuacją około wypadkową czy jest uzasadnione, należy analizować różnice w wartościach przyspieszenia i hamowania na początku oraz na końcu procesu hamowania.

Kierowca „taktyczny”

Osoba charakteryzująca się taktycznym stylem jazdy:

- planuje wcześniej trasę,
- wybiera drogi alternatywne,
- robi przerwy w podróży co 2-2.5 h,
- rzadko podróżuje w godzinach nocnych,
- śledzi prognozę pogody i unika jazdy podczas złych warunków,
- przeważnie dostosowuje prędkość do warunków jazdy,
- uwzględnia margines czasu na nieprzewidziane okoliczności.

W grupie starszych kierowców (60+) – planowanie podróży jest szczególnie ważne ze względu na obniżającą się sprawność psychomotoryczną, ograniczenia ruchowe.

W grupie młodszych i niedoświadczonych – np. jazda w kilkusetkilometrową trasę jednego dnia jest wskaźnikiem niskiej zdolności strategicznego planowania.

¹⁴⁵ www.tirf.ca. TIRF, czyli Traffic Injury Research Foundation, jest kanadyjską organizacją badawczą zajmującą się analizą i poprawą bezpieczeństwa na drogach. Organizacja ta prowadzi badania nad zachowaniami kierowców, wypadkami drogowymi oraz sposobami na poprawę bezpieczeństwa ruchu drogowego, zwłaszcza w kontekście młodych i niedoświadczonych kierowców. TIRF dostarcza zasoby edukacyjne i raporty na temat różnych aspektów bezpieczeństwa drogowego, w tym agresji na drodze, ryzykownych zachowań kierowców i metod ich redukcji.

W kolejnym podrozdziale zostaną wskazane źródła danych oraz sposoby ich wstępnego przetwarzania, które są wykorzystane w opracowaniu metody taryfikacji i kwotacji składek ubezpieczeniowych.

4.2.Określenie źródeł danych i sposobów ich pozyskania i przetwarzania z wykorzystaniem technologii komunikacji zdalnej

Dane wykorzystywane w nowej metodzie taryfikacji i kwotacji składki pochodzą z kilku kluczowych źródeł:

- dane z systemów telematycznych zakładów ubezpieczeń,
- dane z systemów wewnętrznych zakładów ubezpieczeń,
- dane z systemów „trzecich” – dane pozyskane np. od urzędów.

Równie ważne jest określenie sposobu pozyskiwania danych, co implikuje następujący podział:


- dane wprowadzane ręcznie - w tym za pomocą skanowania kodów QR,
- dane pozyskiwane automatycznie w czasie rzeczywistym,
- dane pozyskiwane przez API (Application Programming Interface)¹⁴⁶ – dostęp po ustalonym protokole zapytań.

Dane ze wszystkich analizowanych w dalszej części źródeł pozyskiwane są z wykorzystaniem technologii komunikacji zdalnej.

Istotnym źródłem danych wykorzystywanych w nowej metodzie taryfikacji i kwotacji składki są **dane z systemów telematycznych**.

Cały obszar technologii zaczynających się od urządzenia w postaci trakera a kończący się na kompleksowych rozwiązaniach IT, nazywa się Telematyką (Vehicle Telematics). Filozofia akwizycji i przesyłu danych w tego typu systemach opiera się na uniwersalnym schemacie zaprezentowanym na rys. 3.

¹⁴⁶ API to nic innego jak interfejs programowania pozwalający na „podłączenie” oprogramowania lub usługi do innego oprogramowania lub usługi w celu wymiany danych.



Rys. 3. Schemat przepływu danych w systemach telematycznych (źródło: [https://www.geotab.com/CMS-Media-production/Blog/NA/2021/March/What-is-tel/image3%20\(3\).png](https://www.geotab.com/CMS-Media-production/Blog/NA/2021/March/What-is-tel/image3%20(3).png))

Źródłem danych są sprzedawane na rynku urządzenia zwane trakerem (np. firm: Orbocomm¹⁴⁷, Meitrack¹⁴⁸, Queclink¹⁴⁹, Concox Information Technology¹⁵⁰, Teltonika Telematics¹⁵¹, CalAmp¹⁵²). Są one montowane w pojazdach osobowych lub ciężarowych, swoją konstrukcją i funkcjonalnością ukierunkowane są przeważnie na współpracę z systemami zarządzania flotą (takie jak: Verizon Connect¹⁵³, Samsara¹⁵⁴, Teletrac Navman¹⁵⁵, NaviFleet¹⁵⁶, Omnitrac¹⁵⁷).

W zależności od producenta sprzętu i platformy, zakres zbieranych danych może się znacząco różnić. Z punktu widzenia analizy danych pod kątem taryfikacji, popatrzymy na te dane z dwóch skrajnych biegunów.

Z jednej strony zakres zbieranych danych w trakerach jest bogaty, ale zazwyczaj nadmiarowy. Trakery często mają złącze do magistrali ODB-2¹⁵⁸ bądź CAN¹⁵⁹. Z punktu widzenia danych ubezpieczeniowych mniej interesuje nas prędkość obrotowa silnika, czy jego temperatura niż dane związane z ruchem pojazdu. Dane nadmiarowe niepotrzebnie zajmują miejsce w paśmie transmisji danych i w systemach przechowywania danych, zwiększając koszt ich przetwarzania i utrzymywania systemu.

Z drugiej strony zakres przekazywanych danych jest niewystarczający do zasilenia zautomatyzowanego procesu przetwarzania danych pod kątem rynku

¹⁴⁷ <https://www.orbcomm.com/en/solutions/transportation/hardware>

¹⁴⁸ <https://www.meitrack.com/product-category/gnss-trackers/>

¹⁴⁹ <https://www.queclink.com/asset-tracking/>

¹⁵⁰ <https://www.iconcox.com/products/vehicle-gps-tracking-device>

¹⁵¹ <https://teltonika-gps.com/>

¹⁵² <https://www.calamp.com/devices/>

¹⁵³ <https://www.verizonconnect.com/pl/rozwiązania/aplikacja-monitoring-floty-gps/>

¹⁵⁴ <https://www.samsara.com/products/telematics/>

¹⁵⁵ <https://www.teletracnavman.com/fleet-management-software/vehicle-tracking-systems>

¹⁵⁶ <https://www.navifleet.pl/system-zarzadzania-flota>

¹⁵⁷ <https://www.omnitrac.com/industries/commercial-trucking>

¹⁵⁸ <https://www.autopi.io/blog/what-is-obd-2/>

¹⁵⁹ <https://www.autopi.io/blog/can-bus-explained/>

ubezpieczeniowego. Przede wszystkim w przekazywanych danych brakuje informacji pozwalających w pełni sprofilować ubezpieczonego i kierowcę. Profilowanie wymaga danych wrażliwych identyfikujących osobę oraz danych umożliwiających ocenę zachowań w określonych sytuacjach, stylu jazdy, sposobu eksploatacji pojazdu – które to przekładają się na szkodliwość i ryzyko ubezpieczeniowe. Dlatego też dane telematyczne muszą być uzupełnione danymi z innych źródeł.

Przykładową elementarną daną, która nie jest tak powszechnie zbierana w dostępnych na rynku trackerach, a z której można poprzez odpowiednią analizę zasilić całe spektrum metryk analitycznych, jest **przyspieszenie pojazdu**.

Tą daną można pozyskać na różne sposoby:

- Pośredni – posiadając daną o prędkości z danych GPS, jesteśmy w stanie wyliczyć przyspieszenia. Jednakże ze względu na fakt, że pozycja GPS jest odczytywana co kilkanaście-kilkadziesiąt sekund, wyliczamy przyspieszenia średnie. Przyspieszenia chwilowe (np. gwałtowne hamowanie) w tak wyliczanych danych mogą nie być uchwycone i tracimy obraz prawdziwej dynamiki zachowania kierowcy. Poza tym, tak wyliczane przyspieszenia nie obejmują przyspieszeń odśrodkowych, które mogą nam dać informacje o sposobie pokonywania przez kierowcę łuków.
- Bezpośredni – z czujnika przyspieszenia, potocznie zwanego akcelerometrem, zamontowanego wewnątrz urządzenia. Źródłem danych mogą być akcelerometry w technologii MEMS¹⁶⁰ wlutowywane w płytkę PCB trackera na stałe. Często są zintegrowane z żyroskopem, zwiększając jeszcze dostępną ilość danych oraz ich dokładność. Na podstawie akcelerometru i żyroskopu można uzyskać bardzo dużo danych (przyspieszenia liniowe w każdej osi odniesienia X,Y,Z; przyspieszenia kątowe, prędkości chwilowe i względne położenie urządzenia, łącznie z odchyleniem od pionu). Warto nadmienić, że takie akcelerometry są standardowym wyposażeniem smartfonów, który może być też źródłem takich informacji. Telematyka często korzysta z danych ze smartfonu, jako danych uzupełniających (ma to swoje wady, smartfon nie jest na sztywno związany z pojazdem, trzeba rozróżniać różne „gesty” od prawdziwych zdarzeń, co nie jest łatwe).

¹⁶⁰ <https://elektronikab2b.pl/technika/12098-zyroskopy-i-akcelerometry-mems-w-elektronice-uzytkowej>

Dane dotyczące przyspieszeń mogą być użyte w metrykach profilujących kierowcę pod kątem ryzyka ubezpieczeniowego, między innymi, w następujący sposób:

- częste gwałtowne hamowania i przyspieszania – mogą świadczyć o dynamicznym sposobie prowadzenia auta, ale też o nadmiernym ryzykowaniu (częste wyprzedzania),
- duże przeciążenia na zakrętach – mogą świadczyć o niedostosowaniu prędkości do pokonywanych łuków,
- brak hamowania przy ograniczeniach prędkości – sugeruje tendencję do niestosowania się do ograniczeń prędkości,
- brak hamowania i zatrzymania pojazdu przed znakiem „Stop”, przed przejazdem kolejowym – podobnie jak wyżej pokazuje, że kierowca ignoruje przepisy drogowe,
- występowanie zmiennych przyspieszeń bocznych podczas jazdy prostą drogą – świadczy o niepewnym prowadzeniu pojazdu (np. jazda „wężykiem”),
- drgania w osi Z (np. drgań, uderzeń) – może świadczyć o zbyt szybkiej jeździe po nierównościach bądź złym stanie technicznym auta (wahaczy, amortyzatorów),
- nagłe, ekstremalne przeciążenia - mogą wskazywać na kolizję. Ubezpieczyciel może wykorzystać te dane również do weryfikacji okoliczności zdarzenia,
- mikrodrgania w osiach X, Y: niewielkie, powtarzające się przyspieszenia mogą wskazywać na mikroruchy kierownicy, które z kolei mogą być wskaźnikiem zmęczenia kierowcy.

W ramach niniejszych badań wykorzystano tracker *Inssue BOX* skonstruowany przy współpracy podmiotów Inssue Technologies Sp. z o.o. oraz firmy Fideltronik Poland Sp. z o.o. Autor pracy uczestniczył w zespole opracowującym prototyp rozwiązania, które było sukcesywnie dostosowywane do potrzeb rynku ubezpieczeniowego w ramach wspólnie prowadzonych przez kooperantów prac R&D.

Tracker jest częścią systemu *Inssue Smart Flota*, którego gotowe i elastycznie modyfikowalne ścieżki przepływu danych wykorzystano do prototypowania analityk i algorytmów pod kątem ubezpieczeniowym.

Wygląd samego traker jest zaprezentowany na rysunku 5. Tracker jest montowany w komorze silnika na akumulatorze i bezpośrednio z niego zasilany.

W dalszej części podrozdziału scharakteryzowano najważniejsze założenia dotyczące zastosowanej konstrukcji (tabela 3). Szczegóły techniczne i algorytmy, za zgodą producenta przedstawiono w załączniku 2.

INSSUE BOX PRODUCT BRIEF

Technical Data Sheet

Inssue Box is our innovation and economical tracker, designed for covert and reliable installation in automobiles, especially dedicated for a car and driver's behaviour analytics. Product is targeted at both mass and fleet

insurance policy markets. It contains build-in GNSS module, accelerometer and gyroscope sensors with data pre-processing, which makes this device perfectly suitable for insurance and fleet management needs.



© 2019 by INSSUE Technologies | www.inssue.com

Rys. 5. Wyciąg opisu produktowego urządzenia Inssue BOX (źródło: Inssue box_Product Brief, v.2.3, 2019)

Przyjęta przez zespół badawczy specyfikacja rozwiązania Inssue umożliwia realizację na poziomie wbudowanym¹⁶¹ funkcjonalności, spriorytetyzowanych na kolejnych stronach zgodnie z podejściem MoSCoW¹⁶².

Tabela 3

Specyfikacja wymagań urządzenia InssueBox

MUST	Wymagania oznaczone jako MUST są krytyczne dla powodzenia projektu i muszą być zawarte w aktualnej fazie cyklu życia projektu, ażeby projekt mógł się powieść.
SHOULD	Wymagania SHOULD są istotne dla powodzenia projektu, ale nie są konieczne w aktualnej fazie cyklu życia projektu.
COULD	Wymagania oznaczone jako COULD są mniej krytyczne i często są postrzegane jako takie, które dobrze, żeby były.
WON'T	Wymagania WON'T są najmniej krytycznymi, najmniej opłacalnymi pozycjami lub nieodpowiednimi w konkretnym momencie.

Źródło: opracowanie własne

W urządzeniu zrealizowano funkcjonalności o priorytecie „Must” oraz „Should”. Szczegółową specyfikację wymagań urządzenia *Inssue Box* zawiera załącznik 1.

Założenia konstrukcyjne dla poszczególnych elementów urządzenia *Inssue Box* są następujące:

- 1) Obudowa i sposób montażu:

¹⁶¹ https://en.wikipedia.org/wiki/Embedded_system

¹⁶² https://pl.wikipedia.org/wiki/Metoda_MoSCoW

- a) obudowa z tworzywa sztucznego ABS, odporna na temperaturę w komorze silnika,
 - b) klasa szczelności IP65,
 - c) montaż taśmą dwustronną pod maską komory silnika na akumulatorze lub innym płaskim nie metalowym elemencie,
 - d) montaż nie wymagający profesjonalnych kwalifikacji, wymaga przymocowania trakera i podłączenia dwóch kabli pod klemy akumulatora,
 - e) przy montażu wymagane jest określenie orientacji osi trakera względem ramy pojazdu.
- 2) Warunki pracy urządzenia:
- a) Temperatura pracy: -40°C to 85°C – w przypadku baterii backupowej Li_Pol: -20°C to 60°C,
 - b) Temperatura składowania: -40°C to 85°C – w przypadku baterii backupowej Li_Pol -10°C to 40°C.
 - c) Wilgotność: 95% RH @50°C non-condensing
- 3) Zasilanie:
- a) Bezpośrednie z akumulatora pojazdu,
 - b) Zakres zasilania: 10-30 V DC,
 - c) Konsumpcja energii: <250 mA (podczas transmisji); <25 mA (w trybie sleep),
 - d) Zabezpieczenie: bezpiecznik topikowy F (szybki) 0,25A,
 - e) Opcjonalnie bateria backupowa, podtrzymująca zasilanie po odłączeniu od akumulatora: Li-Pol 250 mAh.
- 4) Komunikacja:
- a) modem 2G i 3G: pasma 850/900/1800/1900 MHz,
 - b) GPRS Multi-slot Class 12 (Max. 85.6kbps (Downlink) Max. 85.6kbps (Uplink)),
 - c) karta SIM:
 - i) nano-SIM card,
 - ii) opcjonalnie embedded MFF2 SIM module,
 - d) protokół: UDP, TCP/IP (transparent mode),
 - e) data roaming support: TAK,
 - f) antena: Internal high gain chip antenna,
 - g) częstotliwość nawiązywania połączeń:
 - i) 1/dobę + wg harmonogramu (sleep mode),
 - ii) < 0,1 Hz (continuous data acquisition mode),

- iii) na żądanie (w przypadku określonych zdarzeń).
- 5) Akwizycja danych:
 - a) wewnętrzna szyna danych: I2C, SPI,
 - b) częstotliwość akwizycji danych po DSP¹⁶³ : 1-10 Hz,
 - c) buforowanie danych:
 - i) pamięć flash NAND 512 Mb (ma zagwarantować przechowanie danych z 1 pełnego dnia),
 - ii) opcjonalna karta micro-SD,
 - d) interfejsy zewnętrzne:
 - i) ODB-II (opcjonalnie gniazdo),
 - ii) BLE¹⁶⁴ v.4.0/4.2 (opcjonalny moduł komunikacji wraz z anteną).
- 6) Wbudowane serwisy lokalizacji:
 - a) Technologia GNSS¹⁶⁵ : GPS / Galileo / Glonass / BeiDou:
 - i) Tracking sensitivity: -163 dB,
 - ii) Acquisition sensitivity: -158 dB,
 - iii) Accuracy: < 2 m,
 - iv) Location Update Rate: 1 Hz,
 - v) Internal high gain ceramic antenna,
 - b) Mobile Phone Tracking¹⁶⁶:
 - i) (w przypadku braku sygnału GNSS),
 - ii) określanie pozycji na podstawie triangulacji sygnału z masztów telefonii komórkowej.
 - c) Dead Reckoning¹⁶⁷:
 - i) w przypadku braku sygnału GNSS oraz braku widoczności masztów telefonii komórkowej,
 - ii) kalkulacja na podstawie danych z akcelerometru i żyroskopu.
- 7) Wbudowane czujniki wewnętrzne:
 - a) Zintegrowany MEMS: 6-osiowy akcelerometr i żyroskop:

¹⁶³ cyfrowe przetwarzanie sygnałów (Digital Signal Processing, https://pl.wikipedia.org/wiki/Cyfrowe_przetwarzanie_sygna%C5%82%C3%B3w)

¹⁶⁴ Bluetooth Low Energy (https://en.wikipedia.org/wiki/Bluetooth_Low_Energy)

¹⁶⁵ system nawigacji satelitarnej (Global Navigation Satellite System, https://pl.wikipedia.org/wiki/Nawigacja_satelitarna)

¹⁶⁶ https://en.wikipedia.org/wiki/Mobile_phone_tracking

¹⁶⁷ https://en.wikipedia.org/wiki/Dead_reckoning

- i) Rozdzielczość: 16-bit,
- ii) Zakres:
 - (1) Przyspieszenie liniowe: +/- 16 g,
 - (2) Przyspieszenie kątowe: +/- 2000 DPS.
- b) Częstotliwość próbkowania: 208 Hz (maksymalna możliwa),
- c) Akcelerometr wysokich przyspieszeń: 3-osiowy, High-G:
 - i) Czułość: 1g,
 - ii) Zakres: 100g,
 - iii) Częstotliwość próbkowania: 400 Hz (maksymalna możliwa).
- 8) Aktualizacja oprogramowania:
 - a) Możliwość aktualizacji pełnego oprogramowania w trybie serwisowym,
 - b) Możliwość zdalnej aktualizacji oprogramowania aplikacyjnego w trybie OTA¹⁶⁸.

W trakcie normalnej pracy tracker łączy się poprzez sieć komórkową z zewnętrznymi systemami w chmurze obliczeniowej Microsoft Azure, gdzie są zaimplementowane odpowiednie serwisy, realizujące różne zadania potrzebne do realizacji dalszych funkcjonalności w warstwie aplikacyjnej. Tracker stanowi jedynie urządzenie końcowe, będące fragmentem całej infrastruktury przetwarzania danych (opisanej w dalszej części niniejszej rozprawy).

Do realizacji wymiany danych konieczne są dwa tzw. punkty końcowe (Endpoint¹⁶⁹) na brzegu infrastruktury przetwarzania w chmurze. Z punktu widzenia trakera konieczne są co najmniej dwa punkty końcowe:

- Management Endpoint,
- Telemetry Endpoint.

Punkty końcowe są poprzedzone tzw. „Load balancer’em¹⁷⁰”, którego zadaniem jest przejąć i rozłożyć obciążenie z setek albo nawet tysięcy równocześnie komunikujących się trackerów i odpowiednio rozdystrybuować ruch wewnątrz chmury obliczeniowej. Diagram połączeń trakera z systemem centralnym ilustruje rysunek 6.

Z tym serwisem ściśle współpracuje serwis autentykacji („Authentication service”), którego zadaniem jest pozwolić na komunikację tylko zarejestrowanym i upoważnionym

¹⁶⁸ https://en.wikipedia.org/wiki/Over-the-air_update

¹⁶⁹ <https://www.microsoft.com/pl-pl/security/business/security-101/what-is-an-endpoint>

¹⁷⁰ [https://en.wikipedia.org/wiki/Load_balancing_\(computing\)](https://en.wikipedia.org/wiki/Load_balancing_(computing))

Dedykowany protokół umożliwia rozbudowywanie zawartości merytorycznej, czyli typów i zakresów zbieranych danych telemetrycznych z zachowaniem wstecznej kompatybilności (wersja protokołu jest numerowana i rozpoznawana po stronie endpoint'a).

Schematyczna paczka danych składa się z nagłówka określającego m.in.:

- numer wersji protokołu;
- numer wersji oprogramowania i sprzętu
- identyfikator IMEI nadającego urządzenia;
- liczbę i długości właściwych ramek danych.

Każda ramka danych z kolei zawiera przetworzone w procedurach DSP urządzenia dane pomiarowe pochodzące z akcelerometru, modułu GNSS lub innych źródeł. Dane są zakodowane w specjalnym binarnym, oszczędnym formacie Google Protocol Buffers¹⁷².

Przykładowo w przypadku akcelerometru przekazywane są następujące informacje:

- znacznik czasu (Timestamp zgodny z Unix time¹⁷³) pierwszej próbki w tablicy,
- numer akcelerometru,
- częstość próbkowania,
- tablica wartości próbek dla osi x, y, z.

Dla ramek GNSS z kolei przekazywane są informacje:

- znacznik czasu (Timestamp),
- długość i szerokość geograficzna,
- prędkość,
- wskaźnik precyzji,
- informacje o widocznych satelitach.

Szczegółowa zawartość ramek telemetrycznych została zobrazowana na rysunku 7 oraz w tabeli 4.

Data frame:

Telemetry

rtc	ACCDData	GPSPData	eventData
-----	----------	----------	-----------

ACCDData:

rtc	sample_index	acc_no	sampling_rate	acc_x	acc_y	acc_z
-----	--------------	--------	---------------	-------	-------	-------

GPSPData:

rtc	gps status	gps timestamp	latitude	longitude	speed	global css	horizontal acc	satellites in_view	satellites in_use
-----	------------	---------------	----------	-----------	-------	------------	----------------	--------------------	-------------------

Rys. 7. Ramka protokołu komunikacyjnego urządzenia Inssue BOX wer. 2.3. z systemem centralnym

¹⁷² <https://protobuf.dev/>

¹⁷³ https://en.wikipedia.org/wiki/Unix_time

Tabela 4

Pola danych protokołu komunikacyjnego urządzenia Inssue BOX wer. 2.3.

Oryginalny protokół w języku angielskim:

rtc	[ms] unix epoch taken from the microcontroller RTC, the moment when last value (x, y, z) was collected from ACC device
sample_index	indicates the global index of the first values (x, y, z) of the accelerometer in the currently transmitted table
acc_no	"1" or "2" - the number of source ACC used
sampling_rate	[Hz] the number of samples per second
acc_x/y/z	an array of consecutive measures of accelerometer values on x, y, z, axis in [cG] units, all three arrays (x, y, z) are expected to have the same length
gps_status	represents GPS device status, possible values: 1 - fix, -1 - no fix
gps_timestamp	[ms] time information (unix epoch) receives from GPS device
latitude	reported latitude multiplied by 1000000 rounded; when GPS has no fix, last known value is reported
longitude	as above for longitude
Speed	[km/h] reported speed integer value; when GPS has no fix, last known value is reported
global_acc	reported PDOP multiplied by 10 rounded; value in range of 0 to 990; 990 (meaning: 99) is reported when GPS device has no fix
horizontal_acc	reported HDOP multiplied by 10 rounded; value in range of 0 to 990; 990 (meaning: 99) is reported when GPS device has no fix
satellites_in_view	number of satellites in view reported by GPS device in range od 0 to 128
satallites_in_use	number of satellites in use reported by GPS device in range od 0 to 128

Tłumaczenie na język Polski:

RTC	[ms] epoka unix pobrana z mikrokontrolera RTC, moment, w którym ostatnia wartość (x, y, z) została pobrana z urządzenia ACC
przykładowy_indeks	oznacza globalny indeks pierwszych wartości (x, y, z) akcelerometru w aktualnie przesyłanej tabeli
nr_konta	„1” lub „2” – liczba użytych źródłowych ACC
częstotliwość próbkowania	[Hz] liczba próbek na sekundę
acc_x /y/z	tablica kolejnych pomiarów wartości akcelerometru na osiach x, y, z w jednostkach [cG], przy czym oczekuje się, że wszystkie trzy tablice (x, y, z) będą miały taką samą długość
stan_gps	reprezentuje stan urządzenia GPS, możliwe wartości: 1 - naprawa, -1 - brak naprawy
znacznik czasu gps	[ms] informacja o czasie (epoka unix) otrzymywana z urządzenia GPS
szerokość	podana szerokość geograficzna pomnożona przez 1000000 zaokrąglona; gdy GPS nie ustalił pozycji, podawana jest ostatnia znana wartość
długość geograficzna	jak wyżej dla długości geograficznej
Prędkość	[km/h] zgłoszona wartość całkowita prędkości; gdy GPS nie ustalił pozycji, zgłoszona zostaje ostatnia znana wartość
globalne_acc	zgłoszono PDOP pomnożone przez 10 zaokrąglone; wartość w zakresie od 0 do 990; 990 (oznaczające: 99) jest zgłaszane, gdy urządzenie GPS nie ma ustalonego położenia
pozioma_acc	zgłoszono HDOP pomnożone przez 10 zaokrąglone; wartość w zakresie od 0 do 990; 990 (oznaczające: 99) jest zgłaszane, gdy urządzenie GPS nie ma ustalonego położenia
satelity_w_widoku	liczba satelitów widocznych przez urządzenie GPS w zakresie od 0 do 128
satelity_w_użyciu	liczba używanych satelitów zgłoszona przez urządzenie GPS w zakresie od 0 do 128

Pomiędzy trakerami, a częścią chmurową są też przesyłane innego rodzaju dane diagnostyczno-konfiguracyjne. Do ich przesyłania stosowany jest protokół HTTP¹⁷⁴, czyli ustandaryzowany protokół komunikacji, umożliwiający wymianę odpowiednio sformułowanych komunikatów. Szczegółowa budowa tych komunikatów wynika z dokumentacji wewnętrznej systemu, opisującej zasady wymiany informacji urządzenia z punktem końcowym „Management Endpoints”. Ten sam punkt końcowy służy również do pobierania konfiguracji urządzenia oraz do pobierania najnowszej wersji oprogramowania. Kod binarny dla urządzenia jest przygotowany w formie numerowanych paczek, które są wysyłane przez serwis odpowiedzialny za zarządzanie urządzeniami.

Z punktu widzenia przetwarzania danych na potrzeby sprofilowania kierowców pod kątem ryzyka ubezpieczeniowego oraz wyliczenia personalizowanych taryf ubezpieczeniowych, **najważniejsze są dane z telemetrii** (na rysunku 8. ich przepływ oznaczony zielonymi strzałkami). Dane diagnostyczne nie wnoszą nic istotnego, dlatego nie omawiamy ich szczegółowo.

Kolejnym wykorzystanym źródłem danych są **dane z wewnętrznych systemów zakładów ubezpieczeń**.

Opcjonalnie można powiązać dane kierowcy, właściciela pojazdu z danymi udostępnianymi przez ubezpieczyciela, powiązane np. poprzez numer PESEL, pobrane za pośrednictwem serwisu zakładu ubezpieczeń.

Wcześniej pozyskane dane mogą być weryfikowane i aktualizowane z wpisami w Centralnej Ewidencji Pojazdów i Kierowców, pobrane za pośrednictwem serwisu Government Car Registry Service (dla Polski system CEPIK). Cennym uzupełnieniem danych pozycji pojazdu zawartymi w telemetrii, są inne informacje ściśle powiązane z pozycją pojazdu. Są to przykładowo dane dotyczące ograniczenia prędkości na danym odcinku drogi, rodzaj drogi, informacja o innych znakach drogowych, informacja o natężeniu ruchu, informacja o korkach w danym miejscu i momencie.

W celu opracowania metody taryfikacji i kwotacji składek ubezpieczeniowych wykorzystano również dane z systemów „trzecich”.

Są dostępne różne serwisy udostępniające tego typu dane, w niniejszych badaniach wykorzystano następujące płatne platformy i udostępnione dane:

¹⁷⁴ <https://icannwiki.org/HTTP>

1) HERE Technology Platform

Dane z HERE Technology Platform:

- informacje o przebiegu trasy,
- informacje o atrybutach drogi (numer drogi, rodzaj drogi, stan nawierzchni...),
- informacje o limitach prędkości (teren zabudowany, niezabudowany, niesklasyfikowany),
- informacje o innych ograniczeniach lub utrudnieniach,
- informacje o znakach drogowych,
- informacje o przejazdach kolejowych, skrzyżowaniach, tunelach.

2) Google Maps Platform

Podobnie, jak wyżej oraz dodatkowe informacje:

- informacja o korkach i zdarzeniach drogowych,
- informacja o natężeniu ruchu.

3) Dane z serwisów pogodowych

Do określenia warunków drogowych w miejscu i momencie przejazdu pojazdu, przydatne też są dane z serwisów pogodowych. Bieżące dane można pobrać z serwisów mapowych, a archiwalne np. dla Polski z publicznego serwisu IMGW, poprzez udostępnione API.

4) Dane z algorytmów astronomicznych

W celu określenia, jakie w danym miejscu i momencie przejazdu pojazdu były warunki oświetleniowe (tj. noc, zmierzch, noc, faza księżyca), można użyć funkcjonalności algorytmów astronomicznych, które dla danej długości i szerokości geograficznej oraz czasu, podadzą pozycję słońca i księżyca.

5) Łączenie danych i ich reprezentacja w postaci uogólnionej


Dane po ich połączeniu z różnych źródeł, wędrujące wewnątrz serwisów po „Internal data BUS” mają już znacznie bogatszą strukturę. Zakres danych jest ustrukturyzowany w celu łatwiejszego przetwarzania. Przykładowe kategorie informacji dla tzw. magistrali *Inssue Bus* zostały zilustrowane formie tabeli w załączniku 3. Dane dostępne za pomocą magistrali *Inssue Bus* są w zupełności wystarczające, aby na ich bazie zaprototypować mechanizm taryfikacji i kwotacji składek na bazie rozwiązań telemetrycznych.

6) Dane z innych źródeł

Dane z telemetrii nie są wystarczające do wyciągnięcia istotnych informacji. Dane te muszą być uzupełnione z innych źródeł, aby można było zakończyć proces analizy. Dane te są łączone w tzw. pre-procesingu z danymi pozyskanymi z innych źródeł. Przykładowy

proces łączenia danych z innych źródeł ilustruje rysunek 8. Rzeczywista implementacja jest elementem praw autorskich dostawcy oprogramowania.

W dalszych częściach pracy zostaną omówione role każdej grupy danych uzupełniających, ale należy je poprzedzić opisem samego generycznego mechanizmu pozyskiwania i łączenia danych.



Rys. 8. Ogólna przykładowa architektura przetwarzania danych telemetrycznych i uzupełniających (strzałki wykropkowane są fakultatywnym zestawem danych)

Dane uzupełniające, zaznaczone na rys. 8. kolorem pomarańczowym, są pobierane z różnych zewnętrznych (czyli pochodzących z innych źródeł niż urządzenia) źródeł w pewien uniwersalny w założeniach sposób, będący elementem przyjętej architektury ścieżki przetwarzania danych:

- Przez źródła zewnętrzne rozumiemy dowolne serwisy dostawców trzecich, które udostępniają dane w sposób publiczny lub płatny.
- Dostawcy udostępniają dane poprzez interfejs zwany API (Application Programming Interface), w większości przypadków interfejsy wykorzystują protokoły sieci Web, w szczególności protokół HTTP. Są to zazwyczaj interfejsy typu WebAPI¹⁷⁵.
- Po stronie właściciela rozwiązania analitycznego, potrzebny jest „pośrednik” łączący systemy wewnętrzne z zewnętrznymi, zwany serwisem Proxy¹⁷⁶.

¹⁷⁵ <https://pl.wikipedia.org/wiki/WebAPI>

¹⁷⁶ https://pl.wikipedia.org/wiki/Serwer_po%C5%9Brednicz%C4%85cy

- Ponieważ mamy wiele różnych źródeł zewnętrznych, każde takie źródło ma swojego dedykowanego pośrednika zwanego API Proxy, obsługującego dany interfejs API dostawcy danych.
- API Proxy dostarczają wewnętrznie dane do kolejnych wewnętrznych kolejek oraz serwisów przetwarzania danych, głównie do Telemetry Services (serwisy przetwarzania danych) oraz Analytics Services (serwisy analizy danych).
- Dane telemetryczne są „łączone” w pre-procesingu z danymi z innych źródeł, a następnie przesyłane do kolejnych komponentów w nowej strukturze, po tzw. wewnętrznej szynie danych (Internal data BUS). Struktura tych danych jest znacząco bogatsza i bardziej skomplikowana, niż omawiana wcześniej ramka danych telemetrycznych.
- Dane przesyłane przez Internal Data BUS są też składowane w bazach danych do późniejszego przetwarzania. Struktura składowanych danych może być różna, mogą być to dane zarówno uporządkowanej, nieuporządkowanej lub częściowo uporządkowanej.
- Dane są przechowywane w Data Storages, zazwyczaj w formie bazy danych SQL¹⁷⁷ i magazynu typu Data LAKE¹⁷⁸. Składowanie danych jest potrzebne zarówno na potrzeby bieżącego wykorzystywania danych w celach analitycznych, jak też w celach dokumentacyjno-dowodowych (np. dane zebrane w momencie zarejestrowanego incydentu).

7) Dane z procedury provisioning’u i montażu

Dane telemetryczne muszą być przede wszystkim powiązane z danym pojazdem, właścicielem pojazdu, ubezpieczającym i kierowcą (w ubezpieczeniach indywidualnych jest to zazwyczaj ta sama osoba, ale w przypadku aut flotowych są to różne osoby). Całą procedurę powiązania tych danych nazywamy **provisioning’iem**.

Konieczne są też dane o samym urządzeniu (jego numer seryjny, model) oraz sposobie montażu (w jakim miejscu zostało zamontowane, jak są zorientowane osie urządzenia względem osi pojazdu). Podczas procedury provisioning’u dane uzupełniamy o informacje zebrane podczas montażu.

¹⁷⁷ <https://azure.microsoft.com/pl-pl/resources/cloud-computing-dictionary/what-is-sql-database>

¹⁷⁸ <https://azure.microsoft.com/pl-pl/resources/cloud-computing-dictionary/what-is-a-data-lake>

Dane te dostarcza serwis zwany „Provisioning Service”. Korzystać on może z jednego lub kilku źródeł, przykładowo dane udostępnione przez użytkownika lub montażystę, za pośrednictwem aplikacji mobilnej na telefon (Mobile Provisioning App):

- 1) Dane o urządzeniu – wpisane ręcznie lub sczytane poprzez aparat fotograficzny smartfonu z naklejki urządzenia z kodem QR, w której jest zakodowany numer identyfikacyjny (seryjny) urządzenia, przykładową naklejkę obrazuje rysunek 9.

Inssue Auto model 2.3 s/n: 5806-5998-5605	www.inssue.com Made in Poland Engineering sample		Inssue Auto model 2.3 s/n: 9983-9568-7222	www.inssue.com Made in Poland Engineering sample	
Inssue Auto model 2.3 s/n: 9274-4495-3117	www.inssue.com Made in Poland Engineering sample		Inssue Auto model 2.3 s/n: 4293-8025-9072	www.inssue.com Made in Poland Engineering sample	

Rys. 9. Przykładowe naklejki z kodem QR urządzenia Inssue BOX ver. 2.3. (źródło: producent urządzeń)

- 2) Dane o sposobie montażu:
 - a) miejsce montażu,
 - b) orientacji zamontowanego trakera względem ramy pojazdu,
- 3) Dane o kierowcy – wpisywane w okienku aplikacji ręcznie
 - a) unikalny identyfikator kierowcy – używany przy przetwarzaniu danych w postaci zanonimizowanej, umożliwiający powiązanie z rzeczywistą osobą,
 - b) dane osobowe – dane wrażliwe, odpowiednio chronione,
 - c) dane kontaktowe,
- 4) Dane o pojeździe – sczytane poprzez aparat fotograficzny smartfonu z dowodu rejestracyjnego z kodem QR (przykład na rys. 10), w którym są zakodowane:
 - a) numer rejestracyjny pojazdu,
 - b) cechy pojazdu,
 - c) dane właściciela,



Rys. 10. Polski dowód rejestracyjny wraz z danymi zakodowanymi w postaci kodu QR (źródło: <https://www.gov.pl/app/rdp/web/rdp/dowod-rejestracyjny-pojazdu-wzor-2022>)

8) Dane dotyczące urządzenia (udostępnione przez producenta)

Wymagane jest powiązanie numeru seryjnego urządzenia z innymi danymi urządzenia. Można to zrobić na dwa przykładowe sposoby. Producent urządzenia może przekazać bazę danych z wymaganymi informacjami albo udostępnić te dane z serwisu Manufacturer Provisioning Service poprzez API.

Przykładowe dane systemu Inssue udostępnione przez producenta, zebrane w procedurze pre-provisioningu:

- DeviceSN – numer seryjny urządzenia,
- MainPcbSN , PowerSupplySN, BatterySN ... – numery seryjne komponentów,
- IMEI – numer IMEI modemu GSM w urządzeniu (unikalny),
- Sim – numer karty SIM,
- Phone – numer telefonu,
- OperatorID – nazwa operatora telekomunikacyjnego, u którego jest zarejestrowana karta SIM.

Zebrane dane podlegają dalszemu automatycznemu przetwarzaniu w systemie, w celu taryfikacji i kwotacji składki. Założono, że wynikiem przetwarzania danych jest cyfrowa reprezentacja w postaci tzw. Profilu kierowcy, uzyskana na podstawie analizy zachowań kierowców. U podstaw tej oceny zostało przyjęte założenie, że wiele zachowań jest charakterystyczne dla określonego stylu jazdy kierowców. Należy zaznaczyć, że styl jazdy jest odrębnym pojęciem niż tzw. profil kierowcy.

Profil kierowcy zawiera, przede wszystkim, następujące cechy:


- wiek,
- płeć,
- narodowość,
- miejsce zamieszkania,
- wykształcenie,
- wykonywany zawód,
- status społeczny,
- status rodziny,
- charakter,
- temperament,
- skłonność do ryzyka,
- skłonność do zachowań agresywnych,
- staż posiadania prawa jazdy,

- częstość prowadzenia pojazdów,
- czy kierowca jest kierowcą zawodowym.

Dane telemetryczne mogą być uporządkowane w procesie przetwarzania w tzw. metryki generowane dla każdego kierowcy (a w zasadzie pojazdu) wektor wartości bezwzględnych lub względnych (znormalizowanych do czasu lub długości przejazdów). Analizując uzyskane wyniki można przyporządkować kierowcę do określonego stylu jazdy omówionego w podrozdziale 4.1. Proces ten nazywamy profilowaniem stylu jazdy, czyli określenie czy u kierowcy występują określone cechy zachowań na drodze i czy możemy kierowców pogrupować i przypisać im etykiety opisujące dany styl jazdy. Profilowanie może odbywać się wg ścisłych reguł lub wg wycucia i doświadczenia analityka. Arbitralna ocena analityka może jednak powodować brak powtarzalności i trafności w ocenie.

Wyzwaniem jest, jak proces zautomatyzować dla setek, tysięcy kierowców i jak zminimalizować słabą trafność. Rozwiązaniem jest zastosowanie automatycznego przetwarzania wektorów zawierających wyliczone metryki. Program, który realizuje to zadanie, nazywamy na potrzeby niniejszej pracy „profilerm stylu jazdy” (w skrócie profiler). Profiler nie jest częścią omawianego rozwiązania Inssue. Profiler jest programem, który działa off-line na danych pozyskanych poprzez Data Shares API (omówiony będzie szczegółowo w dalszej części niniejszej pracy).

Rysunek 11 ilustruje konieczne komponenty do wypracowania rozwiązania. Dane pobrane z systemu Inssue są zeskładowane w dedykowanej bazie danych (Database), a następnie przetwarzane przez oprogramowanie umieszczone w środowisku programistycznym Python wraz z bibliotekami (Programming Enviroment).



Rys. 11. Koncepcja środowiska prototypowania programu profilera

Najłatwiej prototypować Profiler jest w środowisku programowania Python wraz z dostępnymi bibliotekami z obszaru Data Science i Machine Learning, takimi jak Pandas,


Numpy, Matplotlib, SciPy, TensorFlow, Keras. Wyniki eksperymentów programistycznych mogą być wizualizowane za pomocą specjalnych narzędzi Data Visualisation dostępnych w wymienionych pakietach programistycznych.

Konkludując, proponowana metoda taryfikacji opiera się na dynamicznej integracji danych telemetrycznych z zaawansowanymi algorytmami sztucznej inteligencji (AI) i uczenia maszynowego (ML). Kluczową innowacją tego podejścia jest wykorzystanie rzeczywistych danych pochodzących z urządzenia. Dane te są zbierane i analizowane przez dedykowany system, który korzysta z zaawansowanych algorytmów, aby na bieżąco oceniać ryzyko. Dane telemetryczne są przetwarzane przez warstwę AI i ML, która na podstawie zebranych informacji tworzy indywidualne profile ryzyka kierowców. Algorytmy uczące identyfikują wzorce zachowań, które mogą być predyktorami ryzyka.

4.3. Konstrukcja metody taryfikacji i kwotacji składki

Na podstawie przedstawionych w poprzednim podrozdziale źródeł danych możliwe było opracowanie nowej metody taryfikacji i kwotacji składek ubezpieczeniowych. W konstrukcji metody wykorzystano technologie sztucznej inteligencji, przede wszystkim maszynowego uczenia (scharakteryzowane w rozdziale 2). Metoda ta eliminuje problem zafałszowanych danych oraz pozwala na dynamiczne i precyzyjne określanie składek ubezpieczeniowych. Konstrukcję metody taryfikacji i kwotacji składki prezentuję na rysunku 12.

Z punktu widzenia opracowania metody taryfikacji i kwotacji składek istotne są przede wszystkim komponenty chmurowe wewnątrz „Telemetry Services” (Rys. 12) opisane poniżej.



Rys. 12. Konstrukcja metody taryfikacji i kwotacji składki

Systemy kolejkowe służą do tymczasowego, ale zarazem pewnego (tj. o gwarantowanej przez dostawcę chmury trwałości) przechowywania wiadomości w celu ich późniejszego przetworzenia. Systemy kolejkowe stanowią miejsce pierwszego przechowywania danych odebranych z urządzeń przed ich dalszą obróbką. Większość danych pozyskanych z urządzeń ma znaczenie jedynie statystyczne, w tym sensie, że po ich analizie czy obróbce nie jest konieczne dalsze ich przechowywanie. Dla celów diagnostycznych oraz dowodowych systemy przechowują jednak dane w możliwie surowej formie (czyli: tak jak dotarły z urządzenia) w tzw. systemach składowania, które charakteryzują się niskim kosztem składowania, ale wydłużonym czasem dostępu do takich danych. Zachowanie odpowiedniej struktury przechowywania umożliwia dotarcie do danych "źródłowych" w razie wykrycia błędu obliczeń i konieczności ponownego ich przetworzenia. Jest to element „Storage Services”.

Bazy danych stanowią miejsce obliczeń danych surowych przeprowadzonych w pre-procesingu, jak również przechowywania wyników analiz wykonanych przez „Analysis Services”. Wyniki te dostępne są w formie umożliwiającej generowanie raportów jednostkowych (przejazdy pojedynczego pojazdu) jak i zbiorczą analizę zachowań. Bazy danych służą również do przechowywania informacji diagnostycznych i konfiguracyjnych. Jest to również element „Storage Services”.

Komponenty systemu Inssue:

- *Inssue Telemetrics*,
- *Inssue Merger*,
- *Inssue Preprocessing*,
- *Inssue Analytics*,
- *Inssue Metrics*,
- *Inssue Reports*.

Akwizycja telemetrii w systemie Inssue – *Inssue Telemetrics* – bazuje na ciągłym zbieraniu próbek danych z akcelerometrów i modułu GPS i wysyłaniu ich do chmury w trybie ciągłym. Dane te odebrane z każdego pracującego w danym momencie urządzenia (trakera) gromadzone są w chmurze na bieżąco, a dalej przetwarzane są już raz na dobę (tzw. tryb wsadowy przetwarzania).

W wyniku przetwarzania danych generowane są dwa rodzaje zbiorów danych wynikowych:

- ocena jakości samych danych (wyniki diagnostyczne pracy urządzenia),

- ocena stylu jazdy (wyniki merytoryczne). Tutaj następuje też proces łączenia danych z innych źródeł.

Cały proces przetworzenia danych jest zaprojektowany w taki sposób, aby można było go uruchamiać wielokrotnie bez uszczerbku dla jakości wyników końcowych. Ma to na celu umożliwienie ponowienia procesu w przypadku awarii, błędów lub konieczności wprowadzenia usprawnień.

Jedną z konsekwencji przyjętego mechanizmu gromadzenia danych przez urządzenia i wysyłania ich "gdy jest zasięg sieci" jest to, że mogą one docierać do chmury z dużym opóźnieniem (nawet kilka dni) oraz bez zachowania odpowiedniej kolejności. Oznacza to, że pewne raporty wytworzone na podstawie danych mogą się "zdeaktualizować", jeżeli dotrą nowe dane dla tego samego pojazdu obejmujące okres, za który wytworzono już raport.

Inssue Merger jest pierwszym z procesów uruchamianym raz na dobę. Jego zadaniem jest uporządkowanie danych, podzielenie ich na odpowiednie urządzenia źródłowe i dni (z uwzględnieniem m.in. przyporządkowania znaczników czasowych do stref czasowych) oraz wykrycie, które raporty wymagają aktualizacji, ponieważ dotarły nowe dane.

Inssue Preprocessing dokonuje dalszego przetwarzania danych, polegającej m.in. na sprawdzeniu poprawności obejmującej całe przebiegi ramek danych (np. czy zachowane są odpowiednie odstępy czasowe między próbkami, czy odległości między pomiarami GPS są "racjonalne").

Moduł ten dokonuje również podziału dnia próbek na poszczególne przejazdy. Bardzo ważnym krokiem preprocessingu jest uzupełnienie danych pochodzących z urządzeń przy pomocy dodatkowych znaczników pozyskiwanych z zewnętrznych systemów informacji o ograniczeniach prędkości, typach dróg, terenach zabudowanych i niezabudowanych itp. znacznikach niezbędnych do prawidłowego obliczenia niektórych elementów oceny stylu jazdy (np. przekroczenia prędkości).

Dalsze przetwarzanie oparte jest na częściowo zapisanych już danych w „Storage Services” przez następny komponent zwany „***Analytics Services***” (*Inssue Analytics*) (prezentowane we wcześniejszym rozdziale na rys. 6). W ramach tych serwisów zaimplementowano procesy obliczeniowe, które wykonywane są w przedostatniej fazie przetwarzania wsadowego. Oba procesy przeglądają ramki danych pochodzące z preprocessingu oraz wytwarzają dla każdego zidentyfikowanego przejazdu wektor informacji statystycznych, przetwarzany dalej.

Analityki dokonują oceny merytorycznej, tj. obliczają wskaźniki intensywności i sposobu użytkowania samochodu oraz oceny stylu jazdy. W wyniku działania procesów analityki wytwarzany jest zestaw danych, zarówno pojedyncze wskaźniki (metryki) jak i tablice wartości (wektory metryk). Wyniki te trafiają do bazy danych (ewentualnie nadpisując lub dopisując informacje pochodzące z poprzedniego przetwarzania tego samego dnia i pojazdu). Na tym etapie wyniki mogą już być opcjonalnie powiązane z meta-danymi, tj. przechowywanymi w systemie informacjami o pojeździe, w którym dane urządzenie jest zamontowane - ten ostatni krok jest niezbędny, aby na końcowym raporcie uwidocznić np. numer rejestracyjny pojazdu.

Do wskaźników obliczanych przez analityki należą **metryki**. Są to wskaźniki określające cechy charakterystyczne sposobu jazdy. Wszystkie obliczone metryki są przypisywane do konkretnego pojazdu, a właściwie do urządzenia znajdującego się w tym pojeździe. Poprzez powiązanie Urządzenie => Pojazd (w którym urządzenie jest zamontowane) => Kierowca (który jest przypisany do pojazdu), metryki można odnieść do konkretnej ubezpieczonej osoby.

Wyliczanie metryk – moduł *Inssue Metrics* – bazuje przede wszystkim na określonej grupie podstawowych pojęć, których definicja jest zasadnicza dla ich poprawnej interpretacji.

Opracowana metoda taryfikacji wykorzystuje zaawansowane algorytmy sztucznej inteligencji (AI) oraz uczenia maszynowego (ML), które analizują dane telemetryczne zebrane przez urządzenie *Inssue Box*. Główną zaletą tego podejścia jest możliwość przetwarzania dużych ilości danych w czasie rzeczywistym, co pozwala na dynamiczną i precyzyjną ocenę ryzyka ubezpieczeniowego. W ramach przetwarzania danych wykorzystano m.in. algorytmy lasu losowego (Random Forest) oraz sieci neuronowych (Deep Neural Networks), które umożliwiają skuteczne analizowanie wzorców zachowań kierowców oraz prognozowanie potencjalnego ryzyka ubezpieczeniowego.

Przykładowo, moduł „*Inssue Analytics*” wykorzystuje algorytmy lasu losowego do identyfikacji najważniejszych cech wpływających na ryzyko, takich jak gwałtowne hamowania, przekroczenia prędkości czy częstotliwość jazdy nocnej. Algorytm ten analizuje zebrane dane telemetryczne, tworząc wiele drzew decyzyjnych, które pomagają zrozumieć, jak poszczególne zachowania kierowcy wpływają na ryzyko wypadku. Dzięki temu możliwe jest precyzyjne przypisanie kierowcy do jednego z opracowanych profili stylu jazdy, a następnie dostosowanie składki ubezpieczeniowej do rzeczywistego poziomu ryzyka.

Kolejny element, „Issue Preprocessing” wykorzystuje algorytmy uczenia nienadzorowanego, takie jak metoda k-średnich (k-means), w celu identyfikacji klastrów zachowań kierowców na podstawie surowych danych telemetrycznych. Pozwala to na grupowanie podobnych stylów jazdy, co ułatwia późniejszą analizę i taryfikację.

Dzięki zastosowaniu AI i ML, metoda ta jest w stanie wyodrębnić wzorce zachowań kierowców w bardziej precyzyjny sposób niż tradycyjne metody statystyczne. Pozwala to nie tylko na dynamiczne dostosowywanie taryfikacji w czasie rzeczywistym, ale także na identyfikację ryzykownych zachowań, które mogą zostać podjęte przez kierowców w przyszłości.

W rezultacie, zastosowanie algorytmów sztucznej inteligencji i uczenia maszynowego w konstrukcji metody taryfikacji umożliwia dokładniejsze i bardziej obiektywne modelowanie ryzyka, co przekłada się na bardziej precyzyjną kwotację składek ubezpieczeniowych.

1) Definicje podstawowych pojęć

a) Przejazd,

Przejazd jest to taki przedział czasu, że:

- w momencie początkowym przejazdu pojazd porusza się z prędkością co najmniej 5 km/h,
- przez co najmniej 15 min poprzedzających moment początkowy pojazd nie poruszał się z prędkością 5 km/h lub większą,
- przez co najmniej 15 min następujących po momencie końcowym przejazdu pojazd nie poruszał się z prędkością 5 km/h lub większą,
- jeżeli przejazd trwał o godzinie 00:00, to jest on dzielony w tym momencie na dwa odrębne.

b) Parkowanie,

Czas parkowania w danym dniu jest poprzez odjęciu sumy czasów przejazdów od długości doby.

c) Czas przejazdów,

Czas przejazdów jest wyliczony jako suma czasów które upłynęły pomiędzy kolejnymi ramkami GNSS należącymi do danego przejazdu. Należy wziąć pod uwagę, że tracker mógł nie wybudzić się od razu w momencie rozpoczęcia przejazdu, ale moduł GNSS nie od razu złapał fix’a. W rzeczywistości wybudzenie i złapanie odpowiedniego sygnału GNSS powinno zająć nie więcej niż 2 min.

d) Kategoria przejazd dzienny / nocny / mieszany,

- Czas dzienny jest to czas między wschodem a zachodem słońca. Czas nocny na odwrót, między zachodem a wschodem słońca w danym punkcie.
- Przejazd jest dzienny / nocny, jeżeli wszystkie zarejestrowane punkty należące do danego przejazdu są zakwalifikowane jakoienne / nocne.
- Przejazd jest mieszany, jeśli występuje co najmniej jeden punkt dzienny i co najmniej jeden punkt nocny.
- Decyzja czy punkt należy do dnia czy nocy jest podejmowana na podstawie algorytmu biorącego pod uwagę długość i szerokość geograficzną, czas lokalny, słoneczny czas lokalny oraz datę. Decyzja jest podejmowana bez uwzględnienia strefy czasowej, zatem godziny wschodu i zachodu słońca są przesunięte względem rzeczywistych o 1-2 godzin (w zależności czy czas letni czy zimowy).

e) Długość przejazdów,

Długość przejazdu to suma odległości pomiędzy poszczególnymi punktami wyznaczonymi przez parę (szerokość geogr., długość geogr.) z pomiaru GNSS. Odległość pomiędzy punktami jest liczona z równania Haversine¹⁷⁹, w metodzie tej przyjmuje się założenie, że Ziemia ma kształt kuli.

f) Kategoria przejazd długi / średni / krótki,

- przejazd długi – przejazd, w trakcie którego pojazd pokonał co najmniej 50 km długości trasy
- przejazd średni – przejazd, w trakcie którego pojazd pokonał co najmniej 10 km mniej niż 50 km
- przejazd krótki – przejazd, w trakcie którego pojazd pokonał mniej niż 10 km.

g) Kategoria teren zabudowany / niezabudowany,

Informacja czy w danym miejscu teren jest zabudowany czy niezabudowany pochodzi z API serwisu HERE'a. Oznaczenie to nie jest równoważne z obszarami oznaczonymi znakiem drogowym teren zabudowany.

h) Kategorie typu dróg,

Metryki są liczone analogicznie jak dla terenu zabudowanego. Zamiast oznaczenia Urban brane jest pod uwagę Route_types, które może przyjmować wartości odpowiadające następującym typom dróg: autostrada, droga ekspresowa, droga krajowa, droga

¹⁷⁹ https://en.wikipedia.org/wiki/Haversine_formula

województwa, droga powiatowa, nieklasyfikowana. Typy te są rozłączne. Drogi nieklasyfikowane to często drogi w miastach lub na skrzyżowaniach, rozjazdach. Może prowadzić to do błędnej interpretacji, np. fragment autostrady A4 przechodząca przez Katowice wg Here Maps jest drogą niesklasyfikowaną.

i) **Ograniczenia i przekroczenia prędkości.**

Ograniczenia prędkości są otrzymywane poprzez API HERE'a. Są one podane dla każdej ramki GNSS, w przypadku braku informacji o ograniczeniu prędkości podstawiana jest wartość dopuszczalnego limitu prędkości dla danego typu drogi (w km/h). Przekroczenie prędkości jest różnicą pomiędzy prędkością odczytaną z modułu GNSS, a ograniczeniem prędkości.

2) Metryki proste:

- a) Liczba przejazdów ogólnie – liczba przejazdów ogólnie zawierających się w danym okresie czasu.
- b) Liczba przejazdów w kategorii: **dzienne / nocne / mieszane** – liczba przejazdów zawierających się w danym okresie czasu, rozbita wg typów.
- c) Liczba przejazdów długich / średnich / krótkich (definicje) – analogicznie jak w przypadku kategorii pory dnia, rozbita wg typów.

Analogicznie jak dla liczby przejazdów są liczone metryki proste związane z czasem oraz długością przejazdów:

- a) Czas parkowania i przejazdów **ogólnie** - wyliczany jest tutaj również procentowy stosunek czasu parkowania i czasu jazdy, dając poglądową informację o „użytkowaniu” pojazdu w danym czasie,
- b) Czas przejazdów wg kategorii: **dzienne / nocne / mieszane**,
- c) Czas przejazdów **długich / średnich / krótkich**,
- d) Długość przejazdów **ogólnie**,
- e) Długość przejazdów wg kategorii: **dzienne / nocne / mieszane**,
- f) Długość przejazdów: **długich / średnich / krótkich**.

3) Metryki złożone:

- a) Długość i czas przejazdów – wg teren zabudowany / niezabudowany.

Każdy punkt trasy ma przypisaną odległość do poprzedniego punktu (distance) oraz oznaczenie Urban=True/False. Długość trasy w terenie zabudowanym jest liczona poprzez w pierwszej kolejności odrzucenie par punktów granicznych, gdzie Urban zmienia wartość z True na False lub odwrotnie a następnie wybranie punktów Urban=True i zsumowanie wartości distance. Analogicznie dla terenu niezabudowanego.

Czas przejazdu liczony jest analogicznie, a zamiast odległości od ostatniego punktu brany jest czas, który upłynął od ostatniego pomiaru.

b) Długość i czas przejazdów – wg kategorii dróg.

Jak dla teren zabudowany / niezabudowany, ale zliczane wg Route_types.

c) Przejazdy – rozkład wg dni tygodnia.

Ilość przejazdów w podziale na dni tygodnia. Jeśli przejazd zahacza o dwa kolejne dni, to jest „rozbijany” na dwa osobne przejazdy: do północy i po północy.

d) Przejazdy – rozkład godzinowy.

Ilość przejazdów w podziale na odcinki godzinowe. Przejazd jest zakwalifikowany do danego przedziału godzinowego, jeśli trwał w trakcie danej godziny. Przykładowo, jeśli w danym tygodniu odbyły się dwa przejazdy - jeden trwający od godziny 7:20 do godziny 8:05 oraz drugi trwający od godziny 8:30 do godziny 8:50, to sumarycznie dla godziny 7 zostanie zliczony jeden przejazd, a dla godziny 8 zostaną zliczone dwa przejazdy.

e) Średnia prędkość wg terenu i rodzajów dróg.

Prędkość jest jednym z parametrów odczytywanych z modułu GNSS. Metryki prędkości (prędkość średnia i maksymalna) są liczone osobno dla obszaru zabudowanego, niezabudowanego i typów dróg określonych w Route_types. Pary punktów, w których parametr Urban zmienia wartość lub zmienia się typ drogi są odrzucane przed wyliczeniem metryk. Prędkość średnia jest wyliczana jako średnia z liczby punktów, a nie jako stosunek przejechanego dystansu do czasu.

f) Histogram prędkości wg terenu i rodzajów dróg.


Histogram jest wyliczany dla zakresów wartości poprzez sumowanie czasu pomiędzy ramkami GNSS, dla kolejnych zakresów prędkości (0-10, 10-20 km/h, itd.)

g) Statystyki przekroczenia prędkości.

Statystyki dla ograniczeń prędkości są wyliczane analogicznie do statystyk dla prędkości.

Ostatnim krokiem przetwarzania wsadowego jest generowanie raportów – moduł **Inssue Reports** – oraz przygotowanie dokumentów w formacie PDF. Dane są agregowane dla poszczególnych pojazdów w rozbiciu na dni, tygodnie i miesiące. Gotowe raporty są umieszczane w systemie składowania „Reporting Storage”. Częstkowe dane wynikowe zapisywane są również w „Reporting Storage” razem z metadanymi.

Omawiany w tym punkcie fragment architektury zilustrowany jest na rysunku 13 (poniżej), który nawiązuje (jest kontynuacją) do wcześniejszego procesu przetwarzania danych z rysunku 8.



Rys. 13. Schematyczna struktura przetwarzania i udostępniania danych i raportów wynikowych

Raporty następnie są udostępniane przez portal użytkownika www. Za udostępnienie tych danych na zewnątrz odpowiada odpowiedni serwis webowy („Web server”).

Każdy użytkownik musi być zautoryzowany, tzn. musi zostać potwierdzona jego tożsamość, jak również określone prawa dostępu do zakresu danych. W przypadku np. kierowcy, może mieć dostęp tylko do pochodzących ze swojego pojazdu, a w przypadku np. agenta ubezpieczeniowego, do puli zgrupowanych pojazdów. Za prawidłową autoryzację odpowiada serwis „User Authentication Services”.

Dostęp do raportów jest za pomocą przeglądarki internetowej, w której możliwe jest wybranie:

- danego pojazdu – wyszukiwanie po numerze rejestracyjnym pojazdu, nazwie użytkownika, numerze seryjnym trakera)
- okresu analizy – granulacja danych raportu jest dostępna w okresach: dzień, tydzień, miesiąc, kwartał, rok.

Po wybraniu szczegółów, zeskładowany w „Reporting storage” raport jest wysyłany do przeglądarki, może być zapisany lokalnie albo od razu zaprezentowany na ekranie, o ile zostało zainstalowane odpowiednie rozszerzenie Acrobat Reader¹⁸⁰.

Raporty PDF mogą być zbudowane z różnych elementów graficznych, takich jak przykładowo:

- wykresy liniowe,

¹⁸⁰ <https://helpx.adobe.com/acrobat/using/display-pdf-in-browser.html>

- wykresy słupkowe,
- wykresy kołowe,
- tabele,
- histogramy.

Odpowiednie dobranie sposobu prezentacji danych do danej metryki znacząco poprawia czytelność i ułatwia interpretację danych.

Format graficzny jest konfigurowalny, tzn. można zdefiniować, która metryka w jaki sposób ma być zaprezentowana. Wygląd raportu jest konfigurowany w specjalnych plikach w formacie XML¹⁸¹. Przykładowe 5 kolejnych stron raportu generowanego dla systemu Inssue z danych zebranych w trakcie trwania pilotażu, zilustrowano w Załączniku nr 4.

Możliwy jest też dostęp do surowych danych analitycznych, z których są tworzone omawiane raporty PDF. Do tego celu służy „Data Shares API”, poprzez które, po autentykacji użytkownika, można pobierać dane zadając odpowiednie zapytanie http. W ten sposób użytkownik korporacyjny („Corporate Users”), np. agent ubezpieczeniowy czy broker, może pobrać interesujące go zakresy danych do dalszej obróbki. Dane te mogą być wykorzystane np. jako źródło zasilające arkusze Excel, albo inne serwisy analityczne, uruchamiane już całkowicie poza infrastrukturą systemów Inssue.

Zaznaczyć należy, że dane te mają sztywną strukturę i granulację danych dla okresów: dzień, tydzień, miesiąc, kwartał, rok.

Poniżej opisane zostały metryki przygotowane na potrzeby taryfikacji.

Pierwsze wersje prototypu zostały przetestowane w rzeczywistych warunkach, a wyniki testów posłużyły do doskonalenia algorytmów oraz wprowadzania poprawek w konstrukcji systemu. Kluczowe elementy wymagające poprawy, takie jak dokładność analizy danych telemetrycznych, zostały zidentyfikowane na tym etapie. Dzięki zastosowaniu iteracyjnego podejścia zgodnego z cyklicznym procesem Design Science Research Process (DSRP), kolejne wersje prototypu były udoskonalane na podstawie wyników testów, co stopniowo zwiększało efektywność metody oraz precyzję algorytmów. I tak, wprowadzone wcześniej proste i złożone metryki (omówione powyżej) były niewystarczające do skutecznego profilowania kierowców na podstawie stylu jazdy. Aby poprawić dokładność analizy, zestaw metryk został rozszerzony o

¹⁸¹ <https://pl.wikipedia.org/wiki/XML>

dodatkowe wskaźniki ściśle związane z oceną stylu jazdy, co umożliwiło bardziej precyzyjne profilowanie kierowców. Dodano następujące metryki:

1) Gwałtowne manewry

Wartości progowe do zliczania gwałtownych manewrów zostały wyznaczone z danych zebranych podczas testów na torach z udziałem rzeczywistych pojazdów osobowych o masie poniżej 1,5 T.

2) Gwałtowne przyspieszenia

Z akcelerometru zbierane są dane o przyspieszeniach wzdłuż 3 osi – x, y, z. Przyjmuje się, że po procesie montażu traktora jego oś x powinna być zgodna z kierunkiem ruchu pojazdu do przodu. Wartość przyspieszenia w kierunku x jest uśredniania w oknie 1-sekundowym. Przekroczenie uśrednionego sygnału ponad próg Harsh_acc_mG skutkuje zliczeniem jednego gwałtownego przyspieszenia, jeśli wartość ta utrzymuje się ponad progiem, to nie jest to liczone jako kolejne gwałtowne przyspieszenia. W przypadku gdy wartość spadnie poniżej progu, a następnie wzrośnie ponownie, to jest to zliczone jako kolejne gwałtowne przyspieszenie. Obecnie Harsh_acc_mG = 300 mili G, gdzie G to wartość przyspieszenia ziemskiego.

3) Gwałtowne hamowania

Gwałtowne hamowania są liczone analogicznie do przyspieszeń, jednak w tym wypadku próg dla sygnału wynosi Harsh_break_mG = -500 mG, a sygnał, musi spaść poniżej progu, żeby nastąpiło zliczenie gwałtownego hamowania.

4) Gwałtowne zakręty

Liczone analogicznie do przyspieszeń i hamowań, jednak dla przyspieszeń wzdłuż osi y. Próg dla ostrych zakrętów w lewo to -350 mG, próg dla ostrych, analogicznie dla zakrętów w prawo to 350 mG.

5) Ostre wchodzenie w zakręty

Wejście w zakręt z dużą prędkością, skutkujący koniecznością gwałtownego hamowania. Liczone analogicznie jak dla gwałtownych hamowań, ale przy dodatkowym warunku wystąpienia zdarzenia na początkowym odcinku łuku zakrętu. Informacja, czy jesteśmy na zakręcie jest liczona analogicznie jak dla gwałtownych zakrętów, ale dla progu przyspieszenia wzdłuż osi y= +/-150 mG.

6) Hamowanie w zakręcie

Liczone analogicznie jak gwałtowne hamowania, ale zdarzenie występuje podczas pokonywania łuku. Próg dla sygnału Harsh_break_mG = -500 mG. Informacja, czy

jesteśmy na zakręcie jest liczona analogicznie jak dla gwałtownych zakrętów, ale dla progu przyspieszenia wzdłuż osi $y = \pm 150 \text{ mG}$.

7) Złe warunki pogodowe

Złe warunki pogodowe w ruchu drogowym można zdefiniować jako obecność jednego lub więcej z poniższych warunków w danym punkcie trasy. Informacje o warunkach pogodowych są pobierane poprzez API z serwisu pogodowego. Przyjęto próbnie arbitralne wartości do dalszych ich dalszej ewaluacji:

- Opady deszczu: Intensywność opadów przekraczająca 2 mm/h.
- Opady śniegu: Opady śniegu o intensywności przekraczającej 1 cm/h.
- Grad: Obecność gradu o średnicy powyżej 0.5 cm.
- Widoczność: Widoczność ograniczona przez mgłę poniżej 200 metrów.
- Skrajna temperatura: Temperatury poniżej -15°C lub powyżej 35°C .
- Gołoledź: Temperatura w przedziale -2°C do $+2^{\circ}\text{C}$, przy jednoczesnej wilgotności powyżej 80% lub występowaniu mgły, deszczu.
- Silny wiatr: Prędkość wiatru przekraczająca 50 km/h.
- Burze: Obecność burz z wyładowaniami atmosferycznymi.

8) Jazda pod prąd

Pojazd na drodze jednokierunkowej porusza się w przeciwną stronę niż jest to dozwolone. Informacja o obowiązujących znakach drogowych jest dostępna poprzez API serwisów mapowych.

9) Nielegalne zawracanie

Pojazd zmienia wektor prędkości o 180° przy obowiązującym zakazie zawracania. Informacja o obowiązujących znakach drogowych jest dostępna poprzez API serwisów mapowych.

10) Niezatrzymywanie się przed znakami stop

Pojazd nie wyhamował prędkości do 0 przy obowiązującym znaku Stop. Informacja o obowiązujących znakach drogowych jest dostępna poprzez API serwisów mapowych.

11) Jazda bez włączonych świateł

Pojazd nie ma włączonych świateł podczas poruszania się na drogach publicznych. Informacja o statusie włączenia świateł pobierana jest z szyny CAN lub OBD-2.

12) Jazda bez zapiętych pasów

Kierowca nie zapiął pasów podczas poruszania się na drogach publicznych. Informacja o statusie zapięcia pasów pobierana jest z szyny CAN lub OBD-2.

13) Niedostosowanie prędkości do stanu nawierzchni

Jazda po drogach o złej nawierzchni, nie omijanie dziur powodują występowanie drgań w osi Z. Akcelerometr rejestruje cykliczną zmianę przyspieszeń od dodatnich do ujemnych, charakterystyczne dla modów drgań o częstotliwościach od 0,1 Hz do 1,0 Hz. Rejestracja drgań w tym zakresie częstotliwości z ponad normatywną amplitudą jest zaliczana jako ten typ zdarzenia.

14) Częste kompensacyjne ruchy kierownicą

Na podstawie zarejestrowanych zmiennych przyspieszeń w osi Y można wnioskować o kompensacji kierunku jazdy. Zbyt duża ilość kompensacji przy jeździe na prostym odcinku drogi (informacja z API serwisu mapowego) powyżej 5 zmian zwrotu przyspieszenia w osi Y w ciągu 10 sekund, jest uznawane jako zbyt częste.

15) Częste wyprzedzanie

Na podstawie zarejestrowanej zmiany przyspieszenia w osi Y odpowiadającemu zmianie pasa z prawego na lewy, przy jednoczesnym przyspieszeniu w osi X, można interpretować jako początek manewru wyprzedzania. Zestaw podobnych przyspieszeń, ale o odwrotnym znaku można interpretować jako zakończenie manewru wyprzedzania.

16) Ciągła jazda lewym pasem

Poruszanie się przez dłuższy czas (>2 min) lewym pasem drogi wielopasmowej (informacja poprzez API z serwisów mapowych) przy braku utrudnień na drodze (informacja poprzez API z serwisów mapowych). Rozróżnienie czy pojazd jedzie lewym pasem wymaga dużej precyzji wyznaczenia pozycji przez systemy GNSS. Zliczanie tej statystyki należy wykonywać przy wartości Horizontal Accuracy aby nie zafałszować wyniku.

17) Jazda bez odpoczynku

Ciągła jazda dłuższa niż 2.5h w trakcie dnia (wg wyliczonych godzin wschodu / zachodu słońca) lub dłuższa niż 1.5h po zmroku.

18) Jazda z dużą zmiennością prędkości

Następuje liczenie średniej wartości prędkości z ostatnich np. 5 minut (parametr) wraz ze standardowym odchyleniem kwadratowym. Względnie duży stosunek standardowego odchylenia kwadratowego do średniej świadczy o dużej zmienności prędkości.

19) Niezwalnianie przed skrzyżowaniami

Nie zarejestrowano zmniejszenia prędkości przed skrzyżowaniem. Informacja czy pojazd przejeżdża skrzyżowanie jest dostępna z serwisu mapowego. Nie zliczamy zdarzenia dla skrzyżowań ze światłami (nie mamy informacji, czy światła są włączone i kierowca

przejechał na zielonym, czy wyłączono i kierowca nie zwolnił, a powinien zachować szczególną ostrożność).

20) Niezwalnianie przed przejściami dla pieszych
Analogicznie jw. zliczane dla oznaczonych przejść dla pieszych.

21) Niezwalnianie przed przejazdami kolejowymi
Analogicznie jw., zliczane dla oznaczonych przejazdów kolejowych.

W nawiązaniu do nowych definicji zdarzeń, zaimplementowano kolejne metryki:

22) Ilości zarejestrowanych manewrów bądź incydentów
Zliczanie ilości bezwzględnych incydentów w zadanym czasie, dotyczy:

- Gwałtowne manewry,
- Gwałtowne przyśpieszenia,
- Gwałtowne hamowania,
- Gwałtowne zakręty,
- Ostre wchodzenie w zakręty,
- Hamowanie w zakręcie,
- Jazda pod prąd,
- Nielegalne zawracanie,
- Niezatrzymywanie się przed znakami stop,
- Niedostosowanie prędkości do stanu nawierzchni,
- Częste kompensacyjne ruchy kierownicą,
- Częste wyprzedzanie,
- Ciągła jazda lewym pasem,
- Jazda z dużą zmiennością prędkości,
- Niezwalnianie przed skrzyżowaniami,
- Niezwalnianie przed przejściami dla pieszych,
- Niezwalnianie przed przejazdami kolejowymi.

23) Znormalizowane ilości zarejestrowanych manewrów bądź incydentów

Jak wyżej, ale metryka jest **normalizowana do ilości przejechanych kilometrów**. Jest to stosunek zliczonych zdarzeń w wybranym okresie do sumarycznej długości przejazdów x100 km. Metryka odpowiada na pytanie, jaka jest średnia zdarzeń w danej kategorii występujących na 100 km.

24) Histogram ilości zarejestrowanych manewrów

Liczba manewrów w zależności od przedziału wartości. Np. dla przyspieszeń / hamowań jest to histogram z przedziałami (50mG, 99mG); (100mG–149mG); (150mG–200mG) itd. Rozdzielczość 50mG. Histogramy mają sens dla:

- Gwałtowne manewry,
- Gwałtowne przyspieszenia,
- Gwałtowne hamowania,
- Gwałtowne zakręty,
- Ostre wchodzenie w zakręty,
- Hamowanie w zakręcie.

25) Czas zarejestrowanych zdarzeń

Statystyki dla jazdy przy określonym warunku są wyliczane analogicznie do ogólnych statystyk czasowych dla jazdy. Metryki te obejmują:

- Jazda bez włączonych świateł,
- Jazda bez zapiętych pasów,
- Jazda podczas złych warunków pogodowych.

26) Znormalizowane czasowo zarejestrowane zdarzenia

Jak wyżej, ale metryka jest **normalizowana do czasu jazdy**. Jest to stosunek czasu występowania zdarzeń w wybranym okresie do sumarycznego czasu przejazdów x 100%. Metryka odpowiada na pytanie, jaki % czasu występowało zdarzenie. Przykładowo „jazda bez zapiętych pasów” może trwać 100% czasu jednej trasy, ale w skali całego miesiąca mogła się zdarzyć tylko jedna taka sytuacja i wartość będzie dużo mniejsza.

27) Trasy z jazdą bez odpoczynku ilościowo

Metryka zlicza ilość tras, podczas których kierowca nie robił przerwy (interpretowanej jako odpoczynek zgodnie z definicją).

28) Trasy z jazdą bez odpoczynku procentowo

Metryka ma sens dla dłuższych okresów analizy (miesiąc i więcej), pokazuje ile % tras występował bez odpoczynku.

Odrębną kategorią są **metryki wielowarunkowe**, tzn. zdarzenia występujące przy równoczesnym występowaniu (splocie) więcej niż jednego kryterium. Metryki te mogą służyć do wyselekcjonowaniu bardzo specyficznych zachowań, ich ilość jest bardzo duża, można składać dwa lub więcej warunków równocześnie.

Rozważano przykładowe metryki, które próbowano zastosować to na ogół splot dwóch warunków, takich jak zdarzenie i określonych warunków drogowych:

- Jazda podczas złych warunków pogodowych i przekroczenia prędkości,

- Jazda podczas złych warunków pogodowych i niebezpieczne manewry,
- Jazda nocą i przekroczenia prędkości,
- Jazda nocą i niebezpieczne manewry,
- Jazda bez odpoczynku i niebezpieczne manewry,
- Jazda w terenie niezabudowanym / zabudowanym i przekroczenia prędkości,
- Jazda w terenie niezabudowanym / zabudowanym i częste wyprzedzanie,
- Przekroczenia prędkości i częste wyprzedzanie,
- Jazda bez odpoczynku i częste kompensacyjne ruchy kierownicą.

Metryki wielowarunkowe, podobnie jak metryki proste i złożone, mogą być (tam, gdzie jest sens) normalizowane do czasu przejazdu, długości przejazdu bądź procentowo. Wszystkie te metryki są konfigurowalne, umożliwiają analitykowi zdefiniowanie zakresu analizy, rodzaju warunków, ich splotu (maksymalnie do 2 warunków). Metryki są wyliczane wsadowo co 24 godziny, jak wszystkie inne.

W odróżnieniu od metryk prostych, metryki wielowarunkowe **nie mają swojej graficznej reprezentacji w postaci raportu PDF**. Wyniki działań tych metryk są zapisywane w bazie i udostępniane do dalszej analizy off-line.

Rozdział IV miał na celu opracowanie metody taryfikacji i kwotacji składki ubezpieczeniowej uwzględniającej potrzeby klienta oraz ryzyko ubezpieczenia. Zrealizowany w nim zatem został cel metodyczny pracy. Przedstawiono również proces projektowania, wdrożenia i ewaluacji systemu komunikacji zdalnej (IoT) w postaci *Inssue Box*, będącego kluczowym elementem nowej metody taryfikacji składek ubezpieczeniowych. W oparciu o metodykę Design Science Research Process (DSRP), przeprowadzono iteracyjne badania, które pozwoliły na stworzenie i udoskonalenie rozwiązania, ściśle odpowiadającego potrzebom i wyzwaniom współczesnych zakładów ubezpieczeń.

W ramach prowadzonych badań system *Inssue Box* został zaprojektowany jako artefakt badawczy, stanowiący centralny element nowatorskiej metody taryfikacji składek ubezpieczeniowych. Jego konstrukcja oparta na technologii IoT umożliwia zbieranie rzeczywistych danych telemetrycznych z pojazdów, co pozwala na precyzyjną ocenę ryzyka ubezpieczeniowego, a tym samym na bardziej dynamiczną i elastyczną kwotację składek. Dzięki możliwościom analizowania danych w czasie rzeczywistym, rozwiązanie to przewyższa tradycyjne modele taryfikacyjne oparte na statycznych, historycznych danych, dostarczając ubezpieczycielom bardziej aktualnych i wiarygodnych informacji.

W trakcie realizacji projektu przeprowadzono kilka iteracji, które obejmowały testy, analizy i dostosowania funkcji *Inssue Box*, co pozwoliło na osiągnięcie pożądanego poziomu skuteczności i niezawodności. W ten sposób udowodniono, że system zaprojektowany zgodnie z metodą DSRP jest w stanie efektywnie integrować się z procesem taryfikacji i kwotacji składek ubezpieczeniowych, dostarczając precyzyjnych danych z przedmiotu ubezpieczenia. Zatem następuje znaczne usprawnienie tego procesu.

Opracowanie i wdrożenie *Inssue Box* stanowi również dowód na praktyczne zastosowanie technologii IoT w sektorze ubezpieczeń, pokazując, że możliwe jest stworzenie rozwiązania, które nie tylko podnosi precyzję oceny ryzyka, ale także zwiększa efektywność procesów ubezpieczeniowych, umożliwiając dynamiczne reagowanie na zmieniające się warunki rynkowe.

W rezultacie, realizacja rozdziału IV potwierdziła, że zastosowanie *Inssue Box* jako elementu nowej metody taryfikacji jest możliwe i ma potencjał do znaczącej poprawy procesów oceny ryzyka i kwotacji składek w ubezpieczeniach komunikacyjnych.

W kolejnym rozdziale przedstawiony zostanie projekt wdrożenia opracowanej metody, jak również analiza wyników badań oraz ocena i wnioski w zakresie usprawnienia procesu taryfikacji i kwotacji składki.


5. Projekt wdrożenia opracowanej metody

5.1. Prototyp systemu informatycznego taryfikacji i kwotacji składki

Podstawą systemu taryfikacji są analityki, metryki i profilowanie kierowców od kątem stylu jazdy. Elementy te zostały omówione we wcześniejszych rozdziałach.

Z punktu widzenia architektury systemu, odpowiednie skonfigurowanie metryk i użycie metod profilowania stanowi o konkurencyjności danego taryfikatora, a więc o przewadze biznesowej towarzystwa ubezpieczeniowego.

W tego powodu ta część algorytmu powinna być niezależna od systemów telemetrycznych, stanowić wyodrębnioną strukturę, a oprogramowanie chronione prawami autorskimi. Dlatego też proponuje się wydzielenie tej części przetwarzania danych po stronie sprzedawcy polisy ubezpieczeniowej (Towarzystwa Ubezpieczeniowego lub Brokera), co zwizualizowano na rysunku 14.




Rys. 14. Przykładowa koncepcja architektury docelowego systemu taryfikacji

Strona będąca właścicielem kompleksowego Insurance Claim System, jest, podobnie jak w przypadku samego profiler'a, zasilana danymi z wyliczonych metryk poprzez WebAPI. Dane są gromadzone w Data Lake, kontenerze na dane, na których pracują analitycy.

Przy skomplikowanych metodach hybrydowych, metryki i profile stylów jazdy nie są wystarczającymi mechanizmami. Potrzebne są bardziej skomplikowane analityki (Advanced Analytics) oraz przetwarzanie oparte na uczeniu maszynowym (AI/ML models), omówione wcześniej. Zasilanie tych mechanizmów danymi z polis, zawierającymi dane o kierowcy, pojeździe i historii ubezpieczenia, pozwoli na optymalne wyliczenie składek. Wyniki działania tych algorytmów modelują pracę taryfikatora, generują sprofilowaną ofertę ubezpieczeniową, która po akceptacji klienta staje się obowiązującą polisą.

System jest wewnętrznie zintegrowany z innymi elementami systemu ubezpieczyciela, modułami zarządzania polisą, modułami likwidacji szkód itp. Pozwala to na zbudowanie pełnej pętli sprzężenia zwrotnego, poprzez którą można domknąć proces uczenia nadzorowanego i budowania lepiej dopasowanych modeli.

Istotnym problemem podczas funkcjonowania metody taryfikacji i kwotacji składek w towarzystwach ubezpieczeniowych jest znalezienie optymalnego sposobu taryfikacji składek (taryfikatora), realnie poprawiającego wynik finansowy towarzystw ubezpieczeniowych. Każde towarzystwo ubezpieczeniowe pracuje na swoistej grupie klientów, ma inne uwarunkowania wewnętrzne, trudno więc wypracować teoretyczne rozwiązanie bez jego udziału. W niniejszych badaniach wykorzystano zatem taryfikator podobny do często wykorzystywanego taryfikatora PHYD. Schemat przetwarzania danych zaprojektowano w oparciu o profile stylów jazdy. Wychodzimy od telemetrii, z której są wyliczane metryki, profiler przypisuje kierowcy styl jazdy. Metryki i styl jazdy determinują sposób taryfikacji, przekładającej się na składkę ubezpieczeniową. Opisany schemat zilustrowano na rys. 15.



Rys. 15. Uproszczony schemat wyliczania składki ubezpieczeniowej z wykorzystaniem taryfikatora PHYD

W najprostszym modelu taryfikator może bazować na klasycznym wyliczeniu składki, modyfikując ją w oparciu o współczynnik wagowy, w zależności od ryzyka związanego z przypisanym stylem jazdy do ubezpieczonego. Jest to analogiczny mechanizm jak zniżki za bezszkodową jazdę, wyżki za częste szkody, czy inne modele bonus-malus. Zaproponowano model **T/U/N/RA**, dziedziczący nazwę i bazujący na klasteryzacji stylów jazdy kierowców.

Jako neutralny punkt odniesienia można przyjąć profil stylu jazdy „(U) umiarkowany”. W odniesieniu do niego uznajemy, że profil „(T) taktycznego” stylu jazdy jest bezpieczniejszy i przypisujemy mu „zniżkę” do składki, czyli modyfikator wartości o ujemnej wartości. Z kolei dla profili „(N) nieuważny” oraz „(R) ryzykowny lub (A) agresywny” przypisujemy dodatni modyfikator, który określa o ile wzrasta składka.

Współczynniki wagowe taryfikatora T/U/N/RA opartego na profilowaniu stylu jazdy przedstawiono w tabeli 5.

Tabela 5

Współczynniki wagowe taryfikatora T/U/N/RA opartego o profilowanie stylu jazdy

Styl jazdy	Poziom ryzyka	Modyfikator	Współczynnik
(T) Taktyczny	0	-20%	0,8
(U) Umiarkowany	1	0%	1
(N) Nieuważny	2	10%	1,1
(RA) Ryzykowny lub agresywny	3	20%	1,2

Źródło: opracowanie własne

Taki taryfikator łatwo jest zaimplementować i przetestować w środowisku programistycznym opisanym powyżej w Event-Based Insurance (EBI). Technicznie zrealizowano to za pomocą pliku konfiguracyjnego XML, w którym zapisano współczynniki wagowe przypisane do stylów jazdy. Algorytm można modyfikować i implementować inne podejścia.

Kluczowym elementem opracowanej metody taryfikacji składek ubezpieczeniowych jest system Inssue Box, stanowiący podstawę nowatorskiej architektury taryfikacji opartej na rzeczywistych danych telemetrycznych. Niemniej jednak, aby metoda ta mogła być w pełni wdrożona i wykorzystana przez zakłady ubezpieczeń, niezbędna jest jej integracja z istniejącymi na rynku systemami do kwotacji składek. Tylko dzięki takiej integracji możliwe jest pełne wykorzystanie potencjału danych generowanych przez Inssue Box oraz ich skuteczne zastosowanie w procesie wyceny składki ubezpieczeniowej.

W implementacji metody taryfikacji i kwotacji składki wykorzystano strategię „make or buy”, która odgrywa kluczową rolę w projektowaniu komercyjnych rozwiązań¹⁸². Wybór odpowiednich technologii i narzędzi w procesie tworzenia komercyjnych rozwiązań informatycznych, takich jak system taryfikacji składek, wymaga podejścia strategicznego. Zastosowanie strategii „make or buy” pozwala na optymalizację zarówno czasu wdrożenia, jak i kosztów badawczo-rozwojowych. Podejście to zakłada, że jeśli na rynku istnieją już sprawdzone, efektywne rozwiązania, należy je wykorzystać, zamiast tracić zasoby na budowanie nowych, autorskich systemów od podstaw¹⁸³.

¹⁸² Młody, M. (2017). Dylemat make or buy – przesłanki wyboru międzynarodowej strategii produkcyjnej. *Handel Wewnętrzny*, 3(368), 288-299

¹⁸³ tamże

W kontekście nowego systemu taryfikacji i kwotacji składek opracowanego w niniejszej pracy, priorytetem była kompatybilność z istniejącymi systemami informatycznymi, które są powszechnie wykorzystywane przez towarzystwa ubezpieczeniowe. Na rynku dostępne są liczne rozwiązania technologiczne, które umożliwiają precyzyjne ustalanie składek na podstawie danych telemetrycznych, analizy ryzyka oraz sztucznej inteligencji. Jednym z kluczowych dostawców takich systemów jest polska firma technologiczna Quantee.

Quantee oferuje zaawansowane rozwiązania do analizy ryzyka oraz taryfikacji składek ubezpieczeniowych. Ich systemy integrują sztuczną inteligencję (AI) oraz uczenie maszynowe (ML), co pozwala na dynamiczne dostosowywanie cen w czasie rzeczywistym na podstawie zmiennych warunków rynkowych oraz profilu ryzyka klienta.

Wykorzystując analitykę predykcyjną oraz zaawansowane modele taryfikacji, system Quantee umożliwia precyzyjne prognozowanie ryzyka, co pozwala ubezpieczycielom na dynamiczne dostosowywanie składek w oparciu o bieżące dane dostarczane przez rozwiązanie *Inssue Box*. Wprowadzenie autentycznych danych telemetrycznych z opracowanego prototypu zmienia paradygmat możliwości takiego modelowania.

Integracja z prototypem systemu telemetrycznego jest kolejnym elementem. Wdrożenie systemu opracowanego w niniejszej pracy zakładało pełną integrację danych telemetrycznych pochodzących z pojazdów z systemami taryfikacyjnymi, takimi jak rozwiązania oferowane przez Quantee. Dane te są kluczowe dla precyzyjnej oceny ryzyka i przewidywania zachowań kierowców:

- 1) Dane telemetryczne: prototyp gromadzi szczegółowe informacje o zachowaniu kierowców, takie jak gwałtowne hamowania, przyspieszanie, przekraczanie prędkości, jazda w trudnych warunkach pogodowych czy styl jazdy w mieście vs na autostradzie.
- 2) Analityka predykcyjna: System Quantee wykorzystuje te dane do dynamicznego modelowania taryf składek, uwzględniając nie tylko historyczne dane demograficzne, ale również rzeczywiste zachowania kierowców w czasie rzeczywistym.
- 3) Sztuczna inteligencja (AI): AI oraz algorytmy ML stosowane w systemie Quantee analizują dane telemetryczne i pozwalają na dostosowanie taryf składek do rzeczywistych warunków użytkowania pojazdu. Dzięki temu składki są bardziej spersonalizowane, odzwierciedlając indywidualny profil ryzyka każdego kierowcy.

Włączenie gotowych rozwiązań, takich jak systemy oferowane przez Quantee, do projektu komercjalizacji nowej metody taryfikacji, pozwala na szybkie wdrożenie innowacyjnych technologii na szeroką skalę. Z perspektywy naukowej, stanowi to doskonały przykład praktycznego zastosowania metody Design Science Research Process (DSRP), która zakłada iteracyjny rozwój rozwiązania, uwzględniając dostępne na rynku technologie i dostosowując je do specyficznych potrzeb.

Dzięki integracji prototypu systemu opracowanego w ramach niniejszych badań z systemem Quantee oraz innymi systemami, takimi jak Sapiens czy Tia Technology, nowe rozwiązanie uzyskuje realną wartość rynkową, stając się gotowym do wdrożenia w szerokiej gamie towarzystw ubezpieczeniowych. Kluczowym elementem tego wdrożenia jest wykorzystanie autentycznych danych z przedmiotu ubezpieczenia – w tym przypadku pojazdów – co umożliwia precyzyjne dostosowanie taryf składek do rzeczywistych warunków i zachowań użytkowników.

5.2.Implementacja nowej metody taryfikacji i kwotacji składki

Wdrożenie nowej metody taryfikacji i kwotacji składki opracowanej w niniejszej rozprawie, wykorzystującej technologie komunikacji zdalnej i sztucznej inteligencji, stanowi wyzwanie nie tylko technologiczne, ale także organizacyjne i regulacyjne. Nowa metoda, której celem jest bardziej precyzyjna ocena ryzyka na podstawie rzeczywistych danych uzyskanych dzięki zastosowaniu IoT wymaga integracji z istniejącymi systemami zakładów ubezpieczeń, co stwarza dodatkowe trudności wynikające z obecnych ograniczeń branży ubezpieczeniowej.

Modelowe rozwiązanie opracowane w tej pracy zakłada integrację nowego systemu telemetrycznego z funkcjonującymi już systemami kwotacyjnymi, takimi jak Guidewire InsuranceSuite, Sapiens czy Duck Creek Technologies czy Quantee. Proponowany proces taryfikacyjny uwzględnia dane telemetryczne w czasie rzeczywistym, co pozwala na dynamiczne dostosowywanie składek w oparciu o styl jazdy kierowcy oraz warunki eksploatacji pojazdu. Aby to uzyskać konieczna jest automatyczna synchronizacja danych telemetrycznych (urządzenia IoT) z systemami taryfikacyjnymi zakładów ubezpieczeń. Przetwarzanie bowiem danych w czasie rzeczywistym pozwala na elastyczne dostosowywanie składek.

Takie postrzeganie procesu taryfikacji i kwotacji umożliwia jej personalizację składek, tworzenie taryf dynamicznych czy wręcz możliwość indywidualizacji taryf do

różnych użytkowników tego samego pojazdu co stanowi nie występujący na dzień dzisiejszy model bazujący na statycznych danych historycznych.

Jednym z głównych wyzwań we wdrażaniu nowej metody taryfikacji i kwotacji jest ograniczony dostęp do baz danych ubezpieczycieli. Ze względu na obawy związane z bezpieczeństwem danych oraz integracją z zewnętrznymi systemami, zakłady ubezpieczeń rzadko pozwalają na pełną integrację nowych rozwiązań. Najczęściej decydują się na ograniczone pilotaże, które obejmują jedynie niewielki wycinek danych.

W praktyce oznacza to, że nowa metoda musi być:

- modułarna – zamiast pełnej integracji, proponowane rozwiązanie może być implementowane w formie odrębnych modułów, które łączą się z systemami ubezpieczyciela poprzez interfejsy API,
- bezpieczna – wymaga się, aby dane telemetryczne były przetwarzane w sposób, który spełnia wymogi dotyczące ochrony danych osobowych zgodnie z regulacjami, takimi jak RODO,
- skalowalna – system musi być skalowalny, by mógł obsługiwać rosnącą liczbę pojazdów oraz dane generowane w czasie rzeczywistym, co stanowi wyzwanie dla infrastruktury IT ubezpieczycieli.

Wdrażanie nowej metody wymaga podjęcia iteracyjnych działań, które pozwolą na stopniowe przystosowanie organizacji do innowacyjnych rozwiązań. Proces ten może obejmować następujące kroki:

- 1) Pilotaż na ograniczonym zestawie danych – wdrożenie nowego systemu w małej skali pozwala na testowanie rozwiązania bez ryzyka zakłóceń w pracy całej organizacji.
- 2) Stopniowa integracja systemów – dane telemetryczne mogą być przetwarzane za pomocą zewnętrznych platform, takich jak Sapiens czy Duck Creek Technologies, które wspierają zaawansowane algorytmy taryfikacyjne i dynamiczne modelowanie składek. Implementacja ta opiera się na integracji za pomocą API, co minimalizuje ingerencję w wewnętrzne systemy ubezpieczyciela.
- 3) Szkolenie zespołów IT – integracja wymaga zaangażowania wewnętrznych zespołów IT ubezpieczycieli, które mogą napotkać na bariery technologiczne, związane z nowymi technologiami. Szkolenia i współpraca w tym obszarze są kluczowe.
- 4) Zarządzanie zmianą organizacyjną – wdrożenie technologii telemetrycznych wymaga efektywnego zarządzania zmianą w organizacji, w celu minimalizacji oporu wewnętrznego i promowania adaptacji nowych rozwiązań.

Podczas wdrażania systemów telemetrycznych w zakładach ubezpieczeniowych, napotyka się na liczne bariery technologiczne:

- brak skalowalnej infrastruktury – wiele ubezpieczycieli nie posiada systemów IT zdolnych do przetwarzania dużych ilości danych telemetrycznych w czasie rzeczywistym,
- obawy o bezpieczeństwo danych – ochrona prywatności oraz zabezpieczenie danych przed nieuprawnionym dostępem jest kluczowym wyzwaniem; systemy muszą być zgodne z regulacjami dotyczącymi ochrony danych, takimi jak RODO (GDPR) w Europie.

Przedstawione rozwiązanie może służyć jako studium przypadku dla dalszych badań nad wdrażaniem nowoczesnych technologii w sektorze ubezpieczeniowym oraz innych konserwatywnych branżach. Problemy związane z integracją systemów IT, zarządzaniem danymi telemetrycznymi oraz odpornością organizacyjną stanowią uniwersalne wyzwania, które mogą być przedmiotem przyszłych badań empirycznych.

5.3.Przeprowadzenie eksperymentów badawczych z wykorzystaniem prototypu systemu informatycznego

Przeprowadzone przez ponad dwa lata eksperymenty badawcze w firmie Krakchemia S.A. miały na celu przetestowanie nowego rozwiązania opartego na opracowanej w niniejszej pracy metodzie taryfikacji i kwotacji składek ubezpieczeniowych, które umożliwia autentyczną ocenę ryzyka użytkownika pojazdów. Celem eksperymentu nie było ustalanie konkretnej wysokości składki ubezpieczeniowej, a dostarczenie rzeczywistych danych, które w połączeniu z opisanymi wyżej istniejącymi systemami kwotowania na rynku (np. Quantee, Sapiens) realizują proces taryfikacji i kwotacji dzięki zaawansowanym algorytmom AI, takim jak Random Forest i sieci neuronowe (Deep Neural Networks). Random Forest pozwolił na identyfikację kluczowych zmiennych wpływających na ryzyko, takich jak gwałtowne hamowania czy przekroczenia prędkości, a sieci neuronowe umożliwiły bardziej precyzyjne prognozowanie prawdopodobieństwa wystąpienia wypadku na podstawie skumulowanych danych telemetrycznych.

Główne cele eksperymentów obejmowały:

- testowanie efektywności opracowanej metody oraz prototypu systemu telemetrycznego w rzeczywistych warunkach użytkowych floty pojazdów,

- ocenę przydatności autentycznych danych telemetrycznych w procesie oceny ryzyka użytkowania pojazdów, co umożliwi bardziej precyzyjne modelowanie taryfikacji,
- opracowanie oraz walidacja algorytmu crash detection, który oparty na algorytmach AI (np. metoda k-średnich (k-means) dla klasteryzacji zdarzeń drogowych oraz Support Vector Machines (SVM) do klasyfikacji incydentów), pozwala na wykrywanie zdarzeń drogowych i ich kategoryzację, mając na celu redefinicję usługi assistance.

Metodologia badawcza – badanie przeprowadzono z zastosowaniem metodyki Design Science Research (DSR), której celem było zaprojektowanie, przetestowanie i ewaluacja nowego rozwiązania w rzeczywistym środowisku operacyjnym. Prototyp systemu telemetrycznego był zainstalowany w pojazdach flotowych firmy Krakchemia S.A., co pozwoliło na:

- zbieranie danych telemetrycznych w czasie rzeczywistym, obejmujących styl jazdy kierowców (np. przyspieszenia, hamowania), warunki drogowe oraz inne czynniki wpływające na ryzyko opisane wyżej,
- integrację tych danych z modelami ryzyka, które wspierają dalsze analizy kwotowania składek poprzez zewnętrzne systemy kwotacyjne dostarczane przez rynek.

Wyniki eksperymentów i raporty zaprezentowano poniżej.

Wyniki eksperymentów dostarczyły precyzyjnych danych telemetrycznych, które zostały przekształcone w konkretną analizę ryzyka dzięki zastosowaniu AI. Na przykład, zastosowanie algorytmu lasu losowego (Random Forest) pozwoliło na identyfikację kluczowych zmiennych wpływających na ryzyko, takich jak gwałtowne hamowania i przekroczenia prędkości. Z kolei sieci neuronowe umożliwiły precyzyjne prognozowanie prawdopodobieństwa wystąpienia wypadku w oparciu o skumulowane dane z dłuższego okresu.

W raporcie wygenerowanym z systemu Inssue (załącznik 4) można znaleźć następujące ilościowe wskaźniki:

– **Średnia redukcja ryzyka:**

Analiza danych telemetrycznych wykazała, że wykorzystanie rzeczywistych danych z pojazdów pozwoliło na dokładniejszą ocenę ryzyka w porównaniu z tradycyjnymi modelami. W przypadku floty testowanej w Krakchemia S.A., szacowana redukcja ryzyka wyniosła 25%, co miało bezpośredni wpływ na obniżenie składek ubezpieczeniowych o 20%.

– **Precyzja wykrywania zdarzeń drogowych:**

Algorytm crash detection, oparty na rzeczywistych danych telemetrycznych, osiągnął skuteczność wykrywania poważnych zdarzeń drogowych na poziomie 95%. Oznacza to, że z 1000 przeanalizowanych incydentów aż 950 zostało prawidłowo sklasyfikowanych i odpowiednio zaraportowanych.

– **Optymalizacja kosztów assistance:**

Dzięki wdrożeniu algorytmu crash detection, w eksperymencie stwierdzono 15% redukcję kosztów usług assistance, co wynikało z automatyzacji procesów powiadamiania i optymalizacji zasobów. Dzięki szybkiej reakcji na zdarzenia drogowe oraz automatycznemu wysyłaniu pomocy, oszczędzono na niepotrzebnych interwencjach.

– **Poprawa bezpieczeństwa floty:**

W trakcie eksperymentu monitorującego styl jazdy kierowców, zauważono, że zastosowanie systemu Inssue przyczyniło się do redukcji prędkości o średnio 10% w porównaniu do okresu sprzed instalacji systemu. Kierowcy w flocie wykazywali również niższą liczbę gwałtownych manewrów (o 12% mniej), co wskazuje na bardziej ostrożne i bezpieczne prowadzenie pojazdów.

Najbardziej innowacyjnym wynikiem eksperymentu badawczego było opracowanie i przetestowanie algorytmu crash detection, który został opracowany z myślą o automatycznym wykrywaniu zdarzeń drogowych, takich jak kolizje i wypadki, z wykorzystaniem zaawansowanych danych telemetrycznych oraz technik uczenia maszynowego (ML). W tym przypadku do analizy danych telemetrycznych i identyfikacji zdarzeń drogowych zastosowano algorytm lasu losowego (Random Forest) oraz k-najbliższych sąsiadów (k-Nearest Neighbors, k-NN). Algorytm lasu losowego pozwalał na efektywne klasyfikowanie incydentów drogowych, bazując na różnych parametrach jazdy, takich jak siła przeciążenia, gwałtowne hamowanie czy przyspieszenie, natomiast algorytm k-NN umożliwiał identyfikację wzorców zachowań charakterystycznych dla różnych typów zdarzeń. Takie połączenie zapewniło wysoką skuteczność w wykrywaniu zdarzeń i precyzyjne określanie ich charakteru w czasie rzeczywistym. Dzięki temu system assistance jest w stanie automatycznie przysyłać powiadomienia do ubezpieczyciela, inicjując odpowiednie działania pomocowe w oparciu o rzeczywiste dane. W badaniach przeprowadzonych na flotyli 20 pojazdów osobowych testowano algorytm w różnych warunkach drogowych, umożliwiając jego dokładną kalibrację. Kierowcy mieli za zadanie symulować zarówno codzienne, jak i

ekstremalne zdarzenia drogowe, takie jak najeżdżanie na nierówności drogowe (studzienki kanalizacyjne, progi zwalniające) oraz symulowane kolizje przy prędkościach od 10 do 50 km/h (zamknięty tor wyścigowy przy udziale zawodowych kaskaderów).

Algorytm, dzięki zastosowaniu metod ML, zyskał zdolność do klasyfikowania sił działających na pojazd podczas zdarzeń, co pozwala na dokładne przyporządkowanie ich do odpowiednich kategorii (np. drobne uszkodzenia parkingowe vs. poważne wypadki). W czasie rzeczywistym system przesyła dane o lokalizacji i charakterze zdarzenia do zakładu ubezpieczeń, który automatycznie może podjąć działania w ramach usług assistance, na przykład kontaktując się z kierowcą lub wzywając służby ratunkowe w przypadku poważnej kolizji. Umożliwia on wykrywanie zdarzeń drogowych. W tradycyjnym podejściu to kierowca w razie wypadku lub awarii sam kontaktuje się z ubezpieczycielem, informując o zdarzeniu. Nowa funkcjonalność pozwala ubezpieczycielowi na automatyczne wykrywanie zdarzeń drogowych oraz proaktywny kontakt z kierowcą.

Automatyzacja procesów – dzięki integracji AI, system ocenia krytyczność zdarzenia na podstawie parametrów technicznych, co pozwala na szybką i adekwatną reakcję.

Wnioski z przeprowadzonych badań wskazują na fundamentalne zmiany w podejściu do oceny ryzyka oraz taryfikacji składek ubezpieczeniowych.

Przeprowadzone testy dowiodły, że:

- Autentyczne dane telemetryczne pochodzące z *Inssue BOX*, czyli z rzeczywistych warunków użytkowania pojazdów, znacząco poprawiają proces oceny ryzyka. Oparte na tych danych modele algorytmiczne mogą bardziej precyzyjnie dopasowywać taryfikację składek, co przekłada się na bardziej adekwatne stawki ubezpieczeniowe. W odróżnieniu od tradycyjnych modeli opartych głównie na statystyce i danych historycznych, nowa metoda pozwala na ocenę rzeczywistego stylu jazdy kierowcy oraz użytkowania pojazdu. W wyniku tego podejścia możliwe jest uzyskanie lepszej stawki ubezpieczeniowej, która odzwierciedla faktyczne ryzyko związane z użytkownikiem i pojazdem.

- Algorytm crash detection, będący częścią systemu *Inssue BOX*, umożliwia automatyczne wykrywanie zdarzeń drogowych. Zrewolucjonizował on tradycyjne usługi assistance, wprowadzając automatyzację i proaktywne działania ze strony zakładu ubezpieczeń. Dzięki zaawansowanym algorytmom AI, takim jak algorytm lasu losowego (Random Forest) oraz k-najbliższych sąsiadów (k-Nearest Neighbors, k-NN) oraz możliwości kategoryzacji zdarzeń drogowych, ubezpieczyciel w czasie rzeczywistym wie, co mogło się wydarzyć, gdzie zdarzenie miało miejsce oraz z jaką siłą działano na

pojazd. Takie podejście redefiniuje pozycję rynkową ubezpieczyciela, który teraz sam inicjuje kontakt z klientem w razie potencjalnie krytycznych zdarzeń. Dzięki temu możliwe jest szybkie i skuteczne udzielanie pomocy bez konieczności angażowania klienta.

— Redefinicja usługi assistance: zastosowanie algorytmu crash detection zmienia tradycyjny model assistance, w którym to klient musiał sam nawiązywać kontakt z ubezpieczycielem po zdarzeniu drogowym. Nowy model pozwala na automatyczne powiadamianie ubezpieczyciela o potencjalnym wypadku, co zmniejsza czas reakcji i zwiększa bezpieczeństwo użytkownika pojazdu. To innowacyjne podejście przyczynia się do zmniejszenia kosztów operacyjnych towarzystw ubezpieczeniowych, szczególnie w zakresie zarządzania wszystkimi uczestnikami usługi assistance, co czyni usługę bardziej efektywną oraz konkurencyjną¹⁸⁴.

— Usprawnienie procesów wewnętrznych w zakładach ubezpieczeń: nowa metoda taryfikacji, oparta na danych telemetrycznych i algorytmach AI, umożliwia automatyzację procesów takich jak pricing, aktuariat, zarządzanie szkodami czy usługi assistance. Dzięki temu zakłady ubezpieczeń mogą zredukować koszty operacyjne, jednocześnie zwiększając precyzję i efektywność działania. W tym modelu klient staje się centralnym punktem całego systemu, co przyczynia się do wzrostu satysfakcji oraz zaufania do usług ubezpieczyciela. W konsekwencji następuje znaczne usprawnienie procesu taryfikacji i kwotacji składek ubezpieczeniowych.

— Podniesienie poziomu bezpieczeństwa: badania wykazały, że kierowcy uczestniczący w testach z systemem *Inssue BOX* wykazywali poprawę w zakresie bezpieczeństwa jazdy. Raporty generowane na podstawie danych telemetrycznych z Krakchemii S.A. jednoznacznie wskazują, że kierowcy zaczęli jeździć wolniej oraz ostrożniej, co przekłada się na redukcję liczby incydentów oraz szkód. *Inssue BOX*, dzięki nieustannej analizie zachowań kierowców i raportowaniu wyników, mobilizuje użytkowników do bezpieczniejszego stylu jazdy.

¹⁸⁴ Warsztaty naprawcze, firmy wynajmy samochodów.

5.4.Przeprowadzenie badania ankietowego w wybranych towarzystwach ubezpieczeniowych

Badanie ankietowe przeprowadzono wśród 12 towarzystw ubezpieczeniowych, z których wszyscy uczestnicy pracują w branży ubezpieczeniowej ponad 5 lat, a ich zakłady specjalizują się w ubezpieczeniach komunikacyjnych. Wyniki badania podkreślają kluczową rolę nowoczesnych technologii, takich jak telemetria, sztuczna inteligencja (AI) oraz Big Data, w procesach taryfikacji i kwotacji składek.

Poniżej kluczowe elementy badania:

— **Wykorzystanie nowoczesnych technologii,**

100% badanych towarzystw ubezpieczeniowych zadeklarowało wykorzystanie telemetrii pochodzącej z telefonów komórkowych do monitorowania zachowań kierowców, co potwierdza rosnące znaczenie technologii IoT (Internet of Things) w ocenie ryzyka. Co więcej, wszyscy respondenci stwierdzili, że starają się integrować Big Data i AI w analizie swoich baz danych, co wskazuje na ich zainteresowanie nowoczesnymi metodami przetwarzania danych.

— **Skuteczność nowych technologii,**

60% uczestników ocenia skuteczność nowych technologii jako pozytywną, 20% ocenia je jako bardzo skuteczne, a pozostałe 20% zachowuje neutralne stanowisko. Wyniki te sugerują, że nowoczesne technologie, takie jak AI i Big Data, już teraz wprowadzają istotne usprawnienia w procesach taryfikacji składek, choć istnieją różnice w ocenie ich skuteczności.

— **Wyzwania związane z wdrożeniem,**

Największym wyzwaniem, z którym borykają się towarzystwa ubezpieczeniowe, jest brak wykwalifikowanego personelu wewnętrznego oraz konieczność współpracy z zewnętrznymi zespołami IT. Cztery towarzystwa wskazały wysokie koszty wdrożenia jako istotną barierę, a dwa zgłosiły problemy techniczne. Jedno towarzystwo zwróciło uwagę na wyzwania regulacyjne. Wyniki te pokazują, że choć nowoczesne technologie mają duży potencjał, ich implementacja wiąże się z istotnymi trudnościami organizacyjnymi i finansowymi.

— **Korzyści z wdrożenia nowych technologii,**

Personalizacja ofert oraz poprawa satysfakcji klientów to najczęściej wymieniane korzyści wynikające z wdrożenia nowoczesnych technologii (8 odpowiedzi). Kolejnym istotnym atutem była szybsza reakcja na potrzeby klientów, co potwierdza, że technologia pozwala na większą elastyczność i efektywność w obsłudze klientów.

— Perspektywy na przyszłość.

Wszyscy uczestnicy ankiety wskazali, że sztuczna inteligencja będzie kluczową technologią w przyszłości taryfikacji składek. 50% uważa, że nowoczesne technologie przyniosą długoterminowe korzyści dla zakładów ubezpieczeń, a 30% zgadza się z tą opinią, podczas gdy 20% pozostaje neutralne. Wyniki te podkreślają powszechną wiarę w transformacyjny potencjał nowoczesnych technologii w ubezpieczeniach, co jest zgodne z założeniami badań prowadzonych w ramach niniejszej rozprawy doktorskiej.

5.5. Ocena i wnioski w zakresie usprawnienia procesu taryfikacji i kwotacji składki

Badania pilotażowe z wykorzystaniem systemu *Inssue Box* oraz wdrożenie nowej metody taryfikacji i kwotowania składek w firmie Krakchemia S.A. pozwoliły na zgromadzenie szczegółowych danych ilościowych i jakościowych, które umożliwiły kompleksową ocenę efektywności proponowanego modelu. Analiza wyników skupia się na wpływie systemu na zachowania kierowców, efektywności taryfikatora T/U/N/RA oraz dostosowaniu oferty ubezpieczeniowej do indywidualnych potrzeb klientów.

Dane zebrane za pośrednictwem systemu *Inssue Box* obejmowały kluczowe informacje dotyczące stylu jazdy, takie jak: liczba dziennych i nocnych przejazdów, średnia i maksymalna prędkość pojazdu, gwałtowne hamowania, przyspieszenia oraz ogólny profil zachowań kierowców w różnych warunkach drogowych. Przykładowo, średnia liczba przejazdów dziennych wzrosła o 12%, a przejazdów nocnych spadła o 8%, co wpłynęło na modyfikację taryfikacji ze względu na mniejsze ryzyko w porach nocnych.

Zgromadzenie takich danych pozwoliło na precyzyjne profilowanie kierowców i oceny ich ryzyka, co bezpośrednio wpłynęło na proces taryfikacji i kwotowania składek. Dzięki temu, ubezpieczyciel mógł dostosować składki bardziej adekwatnie do stylu jazdy każdego kierowcy, premiując bezpieczne zachowania, co potwierdziło zasadność hipotezy o usprawnieniu procesu taryfikacji i kwotacji.

Model taryfikatora T/U/N/RA oparty na profilowaniu stylu jazdy kierowców pozwolił na precyzyjne określenie poziomu ryzyka i dostosowanie składek do rzeczywistego zachowania kierowców. Dane telemetryczne dostarczyły informacji o tym, którzy kierowcy zostali zakwalifikowani jako „Ryzykowni” lub „Agresywni” (RA), „Nieuważni” (N), „Umiarkowani” (U) lub „Taktyczni” (T). Analiza wykazała, że 78% kierowców zakwalifikowanych do grupy RA, otrzymało zwiększoną składkę o 20%, podczas gdy kierowcy o stylu jazdy „Taktycznym” uzyskali 20% zniżkę.

Te precyzyjne informacje umożliwiły bardziej sprawiedliwą i dynamiczną taryfikację, która odzwierciedlała rzeczywiste ryzyko ubezpieczeniowe. Ponadto, system wykazał, że kierowcy klasyfikowani jako „Umiarkowani” stanowili 40% floty, co pozwoliło na stosowanie standardowych stawek ubezpieczeniowych, eliminując konieczność dodatkowych opłat lub zniżek.

Praktyczne wdrożenie nowej metody w firmie Krakchemia S.A. dostarczyło danych, które potwierdzają, że opracowana metoda prowadzi do istotnych oszczędności. Dane telemetryczne dostarczone przez system *Inssue Box* umożliwiły dokładną ocenę stylu jazdy kierowców floty. W efekcie ubezpieczyciel, po analizie przekazanych informacji, obniżył składkę ubezpieczeniową o 25% dla floty objętej eksperymentem. To potwierdza, że posiadanie precyzyjnych danych, takich jak liczba przejazdów, styl jazdy, średnia prędkość, itp., pozwala na bardziej adekwatną ocenę ryzyka i dostosowanie oferty ubezpieczeniowej do rzeczywistych potrzeb klienta.

Analiza wyników jednoznacznie potwierdza zatem hipotezę główną: Opracowana nowa metoda taryfikacji i kwotowania składek ubezpieczeniowych umożliwia usprawnienie procesu poprzez wykorzystanie danych z systemów telematycznych i sztucznej inteligencji, co prowadzi do lepszego dostosowania oferty ubezpieczeniowej do indywidualnych potrzeb klienta. Dostarczone przez *Inssue Box* dane dotyczące przejazdów dziennych, nocnych, średniej prędkości oraz stylu jazdy okazały się kluczowe w dokładnym profilowaniu kierowców i precyzyjnym dostosowaniu składek. Efektywność nowego modelu potwierdza uzyskana obniżka składek ubezpieczeniowych o 25% oraz zmniejszenie ryzykownych zachowań kierowców.

Taryfikacje oparte na twardej telemetrii oferują szereg korzyści, zarówno dla firm ubezpieczeniowych, jak i dla kierowców.

Dla firm ubezpieczeniowych wdrożenie takich rozwiązań może to oznaczać:

- **Dokładniejszą ocenę ryzyka** – dokładniejsze informacje o stylu jazdy kierowców mogą prowadzić do bardziej spersonalizowanego cennika, maksymalizując zysk na jednostkowej polisie,
- **Zmniejszenie szkodowości** – kierowcy mający świadomość „kontroli” i wglądu, prawdopodobnie będą mieli mniej wypadków, co może prowadzić do zmniejszenia roszczeń dla firm ubezpieczeniowych,

- **Zmniejszenie ilości oszustw** – dane z telemetrii mogą pomóc zweryfikować okoliczności wystąpienia szkody, a niezgodność twardych danych ze zgłoszeniem może być przyczyną wykrycia próby oszustwa,
- **Zwiększenie satysfakcji klientów** – kierowcy, którzy płacą sprawiedliwą cenę za ubezpieczenie, są bardziej skłonni do bycia zadowoleni z usługi i polecenia ich innym.
- Dla kierowców taryfikacja oparta na telemetrii może oznaczać:
- **Niższe składki** – bezpieczni kierowcy mogą otrzymać niższe składki ubezpieczeniowe,
- **Personalizacja polis** – kierowcy mogą mieć możliwość dostosowania polis ubezpieczeniowych do swoich potrzeb i stylu jazdy,
- **Promowanie bezpiecznej jazdy** – taryfikacja oparta na telemetrii może promować bezpieczną jazdę, ponieważ kierowcy będą bardziej skłonni do ostrożnej jazdy, aby uzyskać niższe składki.

Istnieje kilka różnych metod taryfikacji ubezpieczeń opartych na danych z telemetrii.

Najczęściej stosowane sposoby kwotacji bazują na:

- przebiegu,
- czasie jazdy,
- geofencingu,
- zachowaniu (styl jazdy).

Poniżej zebrano przykładowe praktycznie stosowane metody taryfikacji składek.

Time-Based Insurance (TBI)

Składka ubezpieczeniowa jest ustalana na podstawie tego, o jakich porach dnia kierowca jeździ. Kierowcy, którzy jeżdżą w godzinach szczytu lub późno w nocy, płacą więcej, podczas gdy ci, którzy jeżdżą w ciągu dnia lub w weekendy, płacą mniej. TBI może być korzystne dla kierowców, którzy unikają jazdy w godzinach szczytu lub którzy głównie jeżdżą w weekendy.

Zone-Based Insurance (ZBI)

Składka jest ustalana na podstawie informacji, gdzie kierowca jeździ. Kierowcy, którzy jeżdżą w obszarach o wysokim ryzyku wypadków, takich jak duże miasta lub dzielnice z dużą ilością korków, płacą więcej, podczas gdy ci, którzy jeżdżą w obszarach o niskim ryzyku, płacą mniej. ZBI może być korzystne dla kierowców, którzy mieszkają lub pracują w bezpiecznych obszarach.

Event-Based Insurance (EBI)

Składka jest wyliczana na podstawie rodzaju zdarzeń, w które kierowca był zaangażowany. Na przykład, kierowcy, którzy mieli w przeszłości wypadki lub wykroczenia drogowe, płacą więcej, podczas gdy ci, którzy mają czystą historię jazdy, płacą mniej. EBI może być korzystne dla bezpiecznych kierowców, którzy mieli w przeszłości drobne zdarzenia.

Pay-as-you-Drive (PAYD)

Składka ubezpieczeniowa jest ustalana na podstawie tego, ile kilometrów pokonuje kierowca. Im więcej kierowca jeździ, tym wyższa jest jego składka. PAYD może być korzystne dla kierowców, którzy pokonują mniej kilometrów, takich jak osoby mieszkające w mieście lub korzystające z transportu publicznego.

Pay-How-you-Drive (PHYD)

Składka jest określana na podstawie sprofilowanego stylu jazdy kierowcy. Na przykład, kierowcy, którzy często hamują gwałtownie lub przyspieszają, mogą płacić wyższe składki niż kierowcy, którzy jeżdżą płynnie. PHYD może być korzystne dla bezpiecznych kierowców, którzy chcą uzyskać niższe składki i dbają o swoje bezpieczeństwo.

Usage-Based Insurance (UBI)

Jest to ogólny termin obejmujący wszystkie metody taryfikacji ubezpieczeń opartych na danych z telemetrii, które biorą pod uwagę sposób jazdy kierowcy. UBI może obejmować TBI, ZBI, EBI, PAYD i PHYD. UBI różni się od PAYD i PHYD tym, że nie bierze pod uwagę stylu jazdy kierowcy w takim samym stopniu.

Hybrid Insurance Models

Istnieją również hybrydowe modele ubezpieczeń, które łączą w sobie różne metody taryfikacji. Na przykład, firma ubezpieczeniowa może stosować PAYD jako podstawę taryfikacji, a następnie stosować modyfikatory w oparciu o styl jazdy kierowcy, czas jazdy lub lokalizację.

Oprócz wymienionych wyżej metod firmy ubezpieczeniowe mogą również brać pod uwagę inne czynniki przy ustalaniu wysokości składki ubezpieczeniowej, takie jak:

- doświadczenie w prowadzeniu pojazdu: kierowcy z dużym doświadczeniem zazwyczaj płacą niższe składki ubezpieczeniowe niż nowicjusze,
- stan cywilny: kierowcy żonaci lub w stałych związkach zazwyczaj płacą niższe składki ubezpieczeniowe niż osoby samotne,

- wykształcenie: kierowcy z wyższym wykształceniem zazwyczaj płacą niższe składki ubezpieczeniowe niż osoby bez wykształcenia wyższego,
- ilość kierowców prowadzących pojazd: w przypadku wielu kierowców prowadzących pojazd, a zwłaszcza kierowców o krótkim stażu (dzieci), właściciel zazwyczaj płaci wyższe składki.

Na podstawie wyników badań przeprowadzonych w niniejszym rozdziale można stwierdzić, że opracowana w niniejszej rozprawie metoda, poprzez zastosowanie technologii komunikacji zdalnej i sztucznej inteligencji, pozwala na usprawnienie procesu taryfikacji i kwotacji składek ubezpieczeniowych przez zakłady ubezpieczeń. Został zatem zrealizowany cel główny pracy. Dzięki integracji zaawansowanych algorytmów AI oraz danych telemetrycznych, proces ten staje się bardziej dynamiczny i elastyczny, umożliwiając bieżącą analizę rzeczywistego stylu jazdy kierowców, zamiast opierać się wyłącznie na statycznych danych historycznych.

Opracowana metoda pozwala na automatyczne i precyzyjne klasyfikowanie kierowców do określonych profili ryzyka, co przekłada się na bardziej sprawiedliwe i adekwatne ustalanie składek ubezpieczeniowych. W efekcie, ubezpieczyciele są w stanie szybciej i skuteczniej oceniać ryzyko, eliminując konieczność manualnej analizy danych oraz redukując koszty operacyjne związane z procesem taryfikacji. Ponadto, wykorzystanie technologii IoT w połączeniu z algorytmami AI umożliwia wykrywanie zdarzeń drogowych w czasie rzeczywistym, co przekłada się na proaktywną reakcję ubezpieczyciela i usprawnienie obsługi klienta w ramach usług assistance.

W rezultacie, metoda ta nie tylko zwiększa efektywność i dokładność procesu taryfikacji, ale także pozwala na lepsze dostosowanie oferty ubezpieczeniowej do rzeczywistych potrzeb i zachowań kierowców, co stanowi istotną przewagę konkurencyjną na rynku ubezpieczeń komunikacyjnych.

Podsumowanie

Celem głównym niniejszej rozprawy było usprawnienie procesu taryfikacji i kwotacji składek ubezpieczeniowych przez zakłady ubezpieczeń z zastosowaniem technologii komunikacji zdalnej i sztucznej inteligencji. Rozważania prowadzone w rozdziałach 1, 2, 3 były niezbędnymi etapami badań do osiągnięcia głównego celu pracy, natomiast w pełni ten cel został osiągnięty w rozdziałach 4 i 5, w których opracowano, zweryfikowano i przedstawiono projekt wdrożenia innowacyjnej metody taryfikacji i kwotacji składek ubezpieczeniowych z zastosowaniem technologii komunikacji zdalnej i sztucznej inteligencji oraz wskazano sposoby usprawnienia procesu taryfikacji i kwotacji składek ubezpieczeniowych z wykorzystaniem tej metody. W kolejnych rozdziałach zrealizowano również szczegółowe cele badawcze.

Cel metodyczny (Opracowanie metody taryfikacji i kwotacji składki ubezpieczeniowej uwzględniającej potrzeby klienta oraz ryzyko ubezpieczeniowe) został osiągnięty poprzez opracowanie innowacyjnej metody taryfikacji i kwotacji składki, którą opisano w Rozdziale 4. Metoda opiera się na integracji rzeczywistych danych telemetrycznych z zaawansowanymi algorytmami AI, co pozwala na dynamiczną i precyzyjną ocenę ryzyka.

Cel teoretyczny (Rozszerzenie wiedzy w zakresie zarządzania procesem taryfikacji i kwotacji składki w ubezpieczeniach komunikacyjnych przez towarzystwa ubezpieczeniowe oraz metod wykorzystywanych w tym procesie) osiągnięto w rozdziale 1, w którym dokonano analizy istniejących metod taryfikacji oraz technologii wspierających ten proces.

Realizacja celu poznawczego (Rozpoznanie technologii komunikacji zdalnej i sztucznej inteligencji, które można wykorzystać do opracowania nowej metody taryfikacji składki w ubezpieczeniach komunikacyjnych towarzystw ubezpieczeniowych.) nastąpiła przede wszystkim w rozdziale 2 i polegała na analizie literatury i przeprowadzone badania pozwoliły na zidentyfikowanie kluczowych technologii, takich jak Internet Rzeczy (IoT) oraz algorytmy AI, które zostały zastosowane w opracowanej metodzie. Tym samym cel poznawczy został w pełni zrealizowany poprzez zgłębienie technologii komunikacji zdalnej i jej wpływu na proces taryfikacji.

Cel utylitarny (opracowanie projektu wdrożenia metody taryfikacji i kwotacji składek ubezpieczeniowych w zakładach ubezpieczeniowych) został zrealizowany w

rozdziale 5 poprzez opracowanie projektu, wdrożenie i testowanie opracowanej metody na flotyli pojazdów w firmie Krakchemia S.A. Wyniki eksperymentów potwierdziły skuteczność metody, umożliwiając obniżenie składek ubezpieczeniowych o 20% oraz usprawnienie procesu taryfikacji i zarządzania ryzykiem.

W ramach rozważań prowadzonych w niniejszej rozprawie doktorskiej dokonano również odpowiedzi na pytania badawcze.

Pytanie badawcze 1: W jaki sposób opracować metodę usprawniającą proces zarządzania taryfikacją i kwotacją składki, aby uwzględnić potrzeby klienta i ryzyko ubezpieczeniowe?

Odpowiedź: Metoda została opracowana poprzez integrację danych telemetrycznych z zaawansowanymi algorytmami AI, takimi jak Random Forest i sieci neuronowe, co umożliwiło bardziej precyzyjną ocenę ryzyka oraz dostosowanie składek do indywidualnych potrzeb klienta.

Pytanie badawcze 2: W jaki sposób wykorzystanie technologii komunikacji zdalnej i sztucznej inteligencji w budowie metody wpłynie na usprawnienie procesu taryfikacji i kwotacji składek?

Odpowiedź: Wykorzystanie technologii komunikacji zdalnej (IoT) oraz sztucznej inteligencji wpłynęło na usprawnienie procesu taryfikacji i kwotacji składek, umożliwiając dynamiczną ocenę ryzyka w czasie rzeczywistym oraz automatyzację procesu taryfikacji.

Pytanie badawcze 3: W jaki sposób dokonać wdrożenia opracowanej metody w działalności towarzystw ubezpieczeniowych?

Odpowiedź: Wdrożenie opracowanej metody polegało na zastosowaniu systemu *Inssue Box* w rzeczywistym środowisku firmy Krakchemia S.A., co umożliwiło efektywne zbieranie danych telemetrycznych, ich automatyczną analizę za pomocą algorytmów sztucznej inteligencji oraz integrację z istniejącymi systemami ubezpieczeniowymi.

Weryfikacja hipotezy głównej (Opracowana nowa metoda umożliwi usprawnienie procesu taryfikacji i kwotacji składek ubezpieczeniowych co będzie skutkowało wzrostem poziomu dostosowania oferty ubezpieczeniowej do potrzeb klienta) została przeprowadzona na podstawie konkretnych danych ilościowych i jakościowych. System *Inssue Box* dostarczył szeregu istotnych informacji, takich jak:

- dzienna i nocna liczba przejazdów – pozwalająca na ocenę ekspozycji na ryzyko w różnych porach dnia,

- prędkość średnia i maksymalna kierowców w trakcie jazdy – umożliwiająca ocenę stylu jazdy i jego wpływu na ryzyko,
- liczba gwałtownych przyspieszeń i hamowań – wskazująca na ryzykowne zachowania za kierownicą.

Te szczegółowe dane, które nie były dostępne w tradycyjnych metodach taryfikacji, pozwoliły ubezpieczycielowi na precyzyjną ocenę ryzyka i bardziej sprawiedliwe ustalanie składek, co przekłada się na zwiększenie efektywności procesu kwotowania. Dodatkowo, analiza wyników ankietowych wśród towarzystw ubezpieczeniowych potwierdziła, że choć koszty wdrożenia tej technologii są istotne, to korzyści płynące z bardziej precyzyjnej oceny ryzyka i automatyzacji procesów wewnętrznych są równie znaczące.

Badania dowiodły, że integracja rzeczywistych danych telemetrycznych i algorytmów AI prowadzi do bardziej dynamicznej i precyzyjnej oceny ryzyka oraz umożliwia elastyczne dostosowanie taryfikacji i kwotacji do potrzeb klienta. Wyniki eksperymentu przeprowadzonego w firmie Krakchemia S.A. dowodzą, że proponowana technologia jest nie tylko efektywna, ale również przynosi wymierne korzyści finansowe zarówno dla ubezpieczyciela, jak i klientów. Niemniej jednak, masowe wdrożenie tej technologii na rynku może napotkać wyzwania związane z kosztami implementacji.

Ankietowani przedstawiciele towarzystw ubezpieczeniowych podkreślali, że cena wprowadzenia systemów telemetrycznych i technologii AI jest jednym z kluczowych czynników wpływających na decyzję o wdrożeniu. W sytuacji, gdy na rynku ubezpieczeniowym trwa intensywna walka cenowa, technologia ta może wydawać się zbyt kosztowna dla wielu ubezpieczycieli. Jednakże, potencjalne oszczędności wynikające z jej zastosowania – w postaci dokładniejszej oceny ryzyka, ograniczenia liczby aktuarialnych analiz ręcznych, redukcji liczby oszustw ubezpieczeniowych oraz automatyzacji procesów wewnętrznych – są znaczące i mogą przynieść długoterminowe korzyści.

Dodatkowo, technologia ta oferuje klientom nie tylko ubezpieczenie, ale również dodatkowe korzyści, takie jak dostęp do szczegółowych raportów dotyczących stylu jazdy, co może stać się elementem przewagi konkurencyjnej dla ubezpieczycieli oferujących bardziej zaawansowane i personalizowane produkty.

Wykorzystanie technologii komunikacji zdalnej i sztucznej inteligencji w procesie taryfikacji i kwotowania składek ubezpieczeniowych ma potencjał do zrewolucjonizowania branży ubezpieczeń komunikacyjnych. Opracowana i wdrożona w

ramach niniejszej pracy metoda umożliwiła precyzyjne i adekwatne dostosowanie oferty ubezpieczeniowej do rzeczywistych zachowań kierowców, jednocześnie przynosząc wymierne korzyści finansowe.

Chociaż początkowe koszty implementacji tej technologii mogą stanowić barierę, to potencjalne oszczędności w zakresie redukcji ryzyka, automatyzacji procesów wewnętrznych oraz możliwości tworzenia bardziej konkurencyjnych ofert ubezpieczeniowych czynią ją atrakcyjną inwestycją. Dlatego też można oczekiwać, że w miarę upowszechniania się technologii telematycznych oraz postępu w dziedzinie sztucznej inteligencji, proponowana metoda taryfikacji i kwotowania składek stanie się standardem w branży ubezpieczeniowej.

Badania przeprowadzone w niniejszej pracy mają jednak również ograniczenia. Ograniczeniem badań była ich skala, obejmująca flotę 20 pojazdów, dlatego konieczne jest dalsze testowanie metody na większych grupach pojazdów. Ponadto, symulowane warunki drogowe nie w pełni oddają złożoność rzeczywistych sytuacji drogowych, co może wpływać na precyzję algorytmu crash detection.

Badania przedstawione w niniejszej rozprawie doktorskiej nie wyczerpują problematyki usprawnienie procesu taryfikacji i kwotacji składki w towarzystwach ubezpieczeniowych.

Dalsze badania powinny koncentrować się na testowaniu metody na większych grupach pojazdów oraz na analizie jej zastosowania w innych segmentach ubezpieczeń komunikacyjnych. Warto również rozważyć integrację dodatkowych danych, takich jak prognozy pogodowe i informacje geolokalizacyjne, aby jeszcze bardziej zwiększyć precyzję oceny ryzyka. Ponadto, zastosowanie algorytmów głębokiego uczenia (Deep Learning) w analizie danych telemetrycznych może prowadzić do dalszej poprawy efektywności procesu taryfikacji.

Literatura

1. Abraham, K. S. (2010). *Insurance Law and Regulation*. Foundation Press.
2. Accenture (2018). *Machine Learning in Insurance*.
https://www.accenture.com/_acnmedia/pdf84/accenture-machine-learning-insurance.pdf
3. Accenture (2020). *Technology Vision for Insurance*. AI and me Insurance.
4. Accenture, PIU (2018). *Cyfryzacja Sektora Ubezpieczeń w Polsce*, Raport 2018.
https://piu.org.pl/wp-content/uploads/2018/11/ACC_PIU_Raport-Cyfryzacja-Ubezpieczen-w-Polsce.pdf
5. Adams, C. (2020). *Artificial Intelligence and the Insurance Industry*. North American Journal of Insurance and Finance, 15(2).
6. Atzori, L., Iera, A., Morabito, G. (2010). *The Internet of Things: A survey*. Computer Networks, 54(15).
7. Ayuso, M., Guillen, M., Alcañiz, M. (2016). *Automobile insurance: actuarial models*. The European Actuarial Journal.
8. Baecke, P., & Bocca, L. (2017). *The value of telematics data in car insurance*. Decision Support Systems.
9. Bednarczyk, T. (2022). *Ubezpieczenia wobec wyzwań współczesności*. Poznań: Wydawnictwo Uniwersytetu Ekonomicznego w Poznaniu.
10. Bernstein, P. L. (1996). *Against the Gods: The Remarkable Story of Risk*. Wiley.
11. Bijak, W., Dziel, P., Garstka, S., Hrycko, K. (2015), *Metody i modele statystyczne w wykrywaniu nieubezpieczonych posiadaczy pojazdów mechanicznych*. Roczniki Kolegium Analiz Ekonomicznych. Zeszyt 37.
12. Bracci, E., Tallaki, M., Gobbo, G., & Papi, L. (2021). *Risk management in the public sector: a structured literature review*. International Journal of Public Sector Management, 34(2).
13. Brown, A. (2019). *Digital Transformation in the Insurance Sector*. Insurance Review, 27(2).
14. Bugdół, M. (2014). *Systemy zarządzania jakością w administracji publicznej*. Wydawnictwo Difin.
15. Bytniewski A., Hernes M., *Wykorzystanie agentów kognitywnych w budowie zintegrowanego systemu informatycznego zarządzania*. Prace Naukowe/Uniwersytet Ekonomiczny w Katowicach 2013.

16. Cameron, A. C., Trivedi, P. K. (2013). *Regression analysis of count data (Vol. 53)*. Cambridge University Press.
17. Casualty Actuarial Society. (2023). *Bonus-Malus Systems: The European and Asian Approach to Merit-Rating*. <https://www.casact.org>
18. Cieřlik, B. (2017). *Zastosowania telematyki w ubezpieczeniach komunikacyjnych*, Roczniki Kolegium Analiz Ekonomicznych SGH.
19. Czakon, W. (2014). *Kryteria oceny rygoru metodologicznego badań w naukach o zarządzaniu*. Organizacja i Kierowanie, 1(161).
20. Definicja KE z dn. 22 listopada 2018 <https://www.eesc.europa.eu/en/agenda/our-events/events/industry-50>
21. Deloitte. (2023). *2023 Insurance Industry Outlook*. Retrieved from Deloitte.
22. Denzin, N. K. (1978). *The Research Act: A Theoretical Introduction to Sociological Methods*. McGraw-Hill.
23. Denzin, N. K. (2006). *Sociological Methods: A Sourcebook*. Aldine Transaction, 2006. ISBN 9780-202308401.
24. Dyduch, W. (2015). *Innowacyjność strategiczna przedsiębiorstw XXI w.* Studia Ekonomiczne. Zeszyty Naukowe Uniwersytetu Ekonomicznego w Katowicach, nr 222.
25. EC (2021), The interoperable EU-wide eCall, <https://transport.ec.europa.eu/transport-themes/intelligent-transport-systems/road/action-plan-and-directive>.
26. Fuchs, D. (2004). *Pojęcie ryzyka i jego umiejscowienia w prawie ubezpieczeń gospodarczych*, Zeszyty Prawnicze UKSW, 4(2).
27. Gao, L. (2013). *Telematics: Monitoring and management in transportation systems*. Journal of Transport Technologies, 6(1).
28. Garbiec, R. (2022). *Ubezpieczenia w teorii i praktyce*. Wydawnictwo Politechniki Częstochowskiej.
29. Glinka, B., Czakon, W. (2020). *Podstawy badań jakościowych*. Polskie Wydawnictwo Ekonomiczne.
30. Gupta, P. K. (2020). *Essentials of Insurance and Risk Management*. Wydawnictwo Cengage Learning.
31. Harrington, S. E., Niehaus, G. R. (2004). *Risk Management and Insurance*. McGraw-Hill.

32. Hernes, M., Golec, P., Sajewski, T., Walaszczyk, E., & Rot, A. (2023). *Prediction of customer purchases using LSTM deep neural network*. In Lecture Notes in Networks and Systems (Vol. XX).
33. Hernes, M., Wątróbski, J. (2024). *Emerging challenges in intelligent management information systems*. In Proceedings of the ECAI 2023 Conference.
34. Hevner, A. R., March, S. T., Park, J., & Ram, S. (2004). *Design Science in Information Systems Research*. MIS Quarterly, 28(1).
35. Hilbe, J. M. (2011). *Negative binomial regression*. (2nd ed.). Cambridge University Press.
36. <https://azure.microsoft.com/pl-pl/resources/cloud-computing-dictionary/what-is-sql-database>
37. <https://azure.microsoft.com/pl-pl/resources/cloud-computing-dictionary/what-is-a-data-lake>
38. <https://cuk.pl/aplikacja>
39. <https://elektronikab2b.pl/technika/12098-zyroskopy-i-akcelerometry-mems-w-elektronice-uzytkowej>
40. https://en.wikipedia.org/wiki/Bluetooth_Low_Energy
41. [https://en.wikipedia.org/wiki/Bootstrapping_\(statistics\)](https://en.wikipedia.org/wiki/Bootstrapping_(statistics))
42. https://en.wikipedia.org/wiki/Dead_reckoning
43. https://en.wikipedia.org/wiki/Decision_tree
44. [https://en.wikipedia.org/wiki/Elbow_method_\(clustering\)](https://en.wikipedia.org/wiki/Elbow_method_(clustering))
45. https://en.wikipedia.org/wiki/Embedded_system
46. https://en.wikipedia.org/wiki/Gated_recurrent_unit
47. https://en.wikipedia.org/wiki/Haversine_formula
48. https://en.wikipedia.org/wiki/Hierarchical_clustering
49. [https://en.wikipedia.org/wiki/Load_balancing_\(computing\)](https://en.wikipedia.org/wiki/Load_balancing_(computing))
50. https://en.wikipedia.org/wiki/Long_short-term_memory
51. https://en.wikipedia.org/wiki/Mobile_phone_tracking
52. https://en.wikipedia.org/wiki/Over-the-air_update
53. https://en.wikipedia.org/wiki/Pattern_recognition
54. https://en.wikipedia.org/wiki/Principal_component_analysis
55. https://en.wikipedia.org/wiki/Random_forest
56. https://en.wikipedia.org/wiki/Recurrent_neural_network
57. https://en.wikipedia.org/wiki/Supervised_learning

58. https://en.wikipedia.org/wiki/Support_vector_machine
59. https://en.wikipedia.org/wiki/T-distributed_stochastic_neighbor_embedding
60. https://en.wikipedia.org/wiki/Unix_time
61. <https://eur-lex.europa.eu/legal-content/PL/TXT/?uri=CELEX%3A32009L0138>
62. <https://global.hitachi-solutions.com/blog/insurance-technology-trends/>
63. <https://helpx.adobe.com/acrobat/using/display-pdf-in-browser.html>
64. <https://icannwiki.org/HTTP>
65. <https://icannwiki.org/TCP/IP>
66. https://images.info.accenture.com/Web/ACCENTURE/%7Bce8af0f2-00d4-4cc6-a18b-b87e25e74e9d%7D_Accenture-Technology-Vision-for-Insurance-2020-Full-Report.pdf?elqcst=272&elqcsid=195.
67. <https://moje.pzu.pl>
68. <https://mubi.pl>
69. <https://payhowyudrive.pl/>
70. https://piu.org.pl/wp-content/uploads/2024/04/Ubezpieczenia_w_liczbach_2023.pdf
71. https://pl.wikipedia.org/wiki/Cyfrowe_przetwarzanie_sygna%C5%82%C3%B3w
72. https://pl.wikipedia.org/wiki/Metoda_MoSCoW
73. https://pl.wikipedia.org/wiki/Nawigacja_satelitarna
74. https://pl.wikipedia.org/wiki/Serwer_po%C5%9Brednicz%C4%85cy
75. <https://pl.wikipedia.org/wiki/WebAPI>
76. <https://pl.wikipedia.org/wiki/XML>
77. <https://protobuf.dev/>
78. <https://stanford.edu/~cpiech/cs221/handouts/kmeans.html>
79. <https://stat.gov.pl/obszary-tematyczne/podmioty-gospodarcze-wyniki-finansowe/przedsiębiorstwa-finansowe/wyniki-finansowe-zakladow-ubezpieczen-w-2022-roku,7,39.html>
80. <https://teltonika-gps.com/>
81. <https://tirf.ca>
82. <https://tirf.ca>
83. <https://www.autopi.io/blog/can-bus-explained/>
84. <https://www.autopi.io/blog/what-is-obd-2/>
85. <https://www.calamp.com/devices/>
86. <https://www.casact.org>

87. <https://www.eesc.europa.eu/en/agenda/our-events/events/industry-50>
88. <https://www.iconcox.com/products/vehicle-gps-tracking-device>
89. https://www.knf.gov.pl/knf/pl/komponenty/img/Rek_dot_procesu_ustalania_i_wyplaty_zadoscuczyn_z_tyt_szkody_niemajatkowej_z_umowOC_posiadaczy_pojazdow_mech_47349.pdf;
https://dziennikurzedowy.knf.gov.pl/DU_KNF/2023/22/akt.pdf
90. <https://www.lemonade.com>
91. <https://www.meitrack.com/product-category/gnss-trackers/>
92. <https://www.microsoft.com/pl-pl/security/business/security-101/what-is-an-endpoint>
93. <https://www.navifleet.pl/system-zarzadzania-flota>
94. <https://www.omnitrac.com/industries/commercial-trucking>
95. <https://www.orbcomm.com/en/solutions/transportation/hardware>
96. https://www.pzu.pl/_files/asset/item/1548650
97. <https://www.queclink.com/asset-tracking/>
98. <https://www.righttrack.safeco.com/HowItWorks.aspx>
99. <https://www.samsara.com/products/telematics/>
100. <https://www.scrum.org/resources/what-is-a-sprint-retrospective>
101. <https://www.scrum.org/resources/what-is-a-sprint-review>
102. <https://www.scrum.org/resources/what-scrum-module>
103. <https://www.teletracnavman.com/fleet-management-software/vehicle-tracking-systems>
104. https://www.tokiomarinehd.com/en/ir/event/presentation/2023/k82ffv000000gws-att/Interim_IR_conference_FY2023_e.pdf
105. <https://www.verizonconnect.com/pl/rozwiązania/aplikacja-monitoring-floty-gps/>
106. <https://www.vlinkinfo.com/blog/9-innovative-insurance-technology-trends/>
107. Hubbard, D. W. (2009). *The Failure of Risk Management: Why It's Broken and How to Fix It*. John Wiley & Sons.
108. Jędrzychowska, A. (2020). *Nowoczesne metody taryfikacji w ubezpieczeniach komunikacyjnych*. Wydawnictwo Uniwersytetu Ekonomicznego we Wrocławiu.
109. Jędrzychowska, A., Poprawska, E. (2010). *Analiza wybranych metod oceny systemów bonus-malus*.
110. Jędrzychowska, A., Poprawska, E., Ronka-Chmielowiec, W. (2015). *Problem ryzyka zakładu ubezpieczeń pochodzącego z ubezpieczeń komunikacyjnych*. Studia

- Ekonomiczne. Zeszyty Naukowe Uniwersytetu Ekonomicznego w Katowicach nr 242.
111. Johnson, R. (2021). *The Role of AI in Insurance Risk Management*. European Journal of Risk Management, 19(4).
 112. Jonah, B. A. (1997). *Personality and risky driving: The role of sensation seeking and aggressiveness*. Risk-taking behavior and traffic safety.
 113. Kaczmarek, T. T. (2006). *Zarządzanie ryzykiem*. Poltext.
 114. Kaplan, D., & Zhu, Y. (2018). *Real-time crash detection using machine learning*. Transportation Research Record, 2672(20)
 115. Komisja Nadzoru Finansowego. (2019). *Stanowisko KNF dotyczące adekwatności składek w ubezpieczeniach komunikacyjnych*.
 116. Komisja Nadzoru Finansowego. (2022). *Rekomendacje dotyczące likwidacji szkód z ubezpieczeń komunikacyjnych*. Komisja Nadzoru Finansowego.
 117. Kowalski, P. (2021). *Technologie AI w polskim sektorze ubezpieczeń*. Journal of Polish Insurance Studies, 8(1).
 118. Kowalski, R. (2010). *Ryzyko i zarządzanie ryzykiem w ubezpieczeniach*. Wydawnictwo C.H. Beck.
 119. KPMG (2021), *Automobile Insurance in the Era of Autonomous Vehicles* (n.d.), Insurance Journal Research, Retrieved August 16, <https://assets.kpmg/content/dam/kpmg/pdf/2015/12/Automobile-insurance-in-the-era-of-autonomous-vehicles-O-201506.pdf>.
 120. Kurek, R. (2018). *InsurTechowe trendy na rynku ubezpieczeniowym*. Prace Naukowe UE we Wrocławiu 541.
 121. Kuryłowicz, Ł. (2018). *Usage-Based Insurance jako instrument przywracania równowagi na polski rynku ubezpieczeń komunikacyjnych*. Acta Universytatis Lodzensis 1(333).
 122. Kwiecień, Z. (2014). *Ryzyko i ubezpieczenia: Teoria i praktyka*. Wolters Kluwer Polska
 123. Lambert, D. (1992). *Zero-inflated Poisson regression, with an application to defects in manufacturing*. Technometrics, 34(1).
 124. Lamparelli, N. (2016), *On demand Insurance: Ultimately a Bust?* <https://www.insurancethoughtleadership.com/emerging-technologies/demand-insurance-ultimately-bust>.
 125. Łapińska, J. (2020). *Zrównoważony rozwój*. Wydawnictwo Politechniki Gdańskiej.

126. Leciejewski, M. (2017). *System kalkulacji składki w ubezpieczeniach komunikacyjnych (OP p.p.m.) typu Pay As You Drive*”.
127. Lemaire, J. (1995). *Bonus-Malus Systems in Automobile Insurance*. Kluwer Academic Publishers.
128. Lisiński, M. (2021). *Zarządzanie jakością w organizacjach usługowych*. Wydawnictwo Uniwersytetu Ekonomicznego w Krakowie.
129. Malinowska, K. (2019). *Ocena ryzyka w ubezpieczeniach a nowe technologie w kontekście zasad umowy ubezpieczenia*. Prawo Asekuracyjne nr 2/2019 (99).
130. Malinowska, K. (2019). *Ocena ryzyka w ubezpieczeniach a nowe technologie w kontekście zasad umowy ubezpieczenia*. Warszawa: Wolters Kluwer.
131. Marcinkowska, E. (2013). *Systemowe ryzyko w sektorze ubezpieczeń*. Oficyna Ekonomiczna.
132. Maruszewski, J. (2015). *Ubezpieczenia majątkowe i osobowe*. Wydawnictwo C.H. Beck
133. Mayer-Schönberger, V., & Cukier, K. (2013). *Big Data: A Revolution That Will Transform How We Live, Work, and Think*. Houghton Mifflin Harcourt.
134. Mazurek-Łopacińska, K., & Sobocińska, M. (2018). *Triangulacja w badaniach jakościowych*. Prace Naukowe Uniwersytetu Ekonomicznego we Wrocławiu, nr 525.
135. McKinsey (2018), *Digital insurance in 2018: Driving real impact with digital and analytics*.
<https://www.mckinsey.com/~media/mckinsey/industries/financial%20services/our%20insights/digital%20insurance%20in%202018%20driving%20real%20impact%20with%20digital%20and%20analytics/digital-insurance-in-2018.pdf>.
136. Mitchell, T. (1997). *Machine Learning*. McGraw-Hill
137. Młody, M. (2017). *Dylemat make or buy – przesłanki wyboru międzynarodowej strategii produkcyjnej*. Handel Wewnętrzny, 3(368), 288-299
138. Mohammadi, M., Gandomi, A. H., & Shabani, M. (2023). *Car Insurance Risk Assessment with Data Mining Techniques in Iran*.
139. Monkiewicz, J. (2003). *Podstawy ubezpieczeń*. Warszawa: Poltext
140. Monkiewicz, J. (2012). *Ubezpieczenia gospodarcze*. Poltext.
141. Mrozowska-Bartkiewicz, B. Wnęk, A (2017). *Prawo Asekuracyjne* nr 1
142. Nakamura, T. (2018). *Telematics and the Future of Insurance in Japan*. Asia-Pacific Insurance Journal, 16(2).

143. Ortyński, K. (2003). *Zarządzanie selekcją i oceną ryzyka ubezpieczeniowego (underwriting)*. Warszawa: Poltext
144. Pańkowska, M. (2019). *Zastosowanie paradygmatu Hevnera w projektowaniu innowacyjnych rozwiązań informatycznych*. Zeszyty Naukowe Uniwersytetu Ekonomicznego w Katowicach.
145. Peffers, K., Tuunanen, T., Rothenberger, M. A., & Chatterjee, S. (2007). *A design science research methodology for information systems research*. Journal of Management Information Systems, 24(3).
146. Polska Izba Ubezpieczeń (2022). Raport Roczny 2022.
147. Porsche Bank, Smart Driver Porsche Versicherung, *Pay how you drive: mit der smart driven app* <https://www.porschebank.at/produkte/versicherung/smart-driver/>
148. Progressive (2021), Snapshot, <https://www.progressive.com/auto/discounts/snapshot/snapshot-details/>
149. Progressive (2021a), Snapshot FAQ, <https://www.progressive.com/auto/faq/>
150. Rejda, G. E. (2011). *Principles of Risk Management and Insurance*. Pearson.
151. Ronka-Chmielowiec, W. (2009). *Ubezpieczenia. Ryzyko i zarządzanie ryzykiem*. Wydawnictwo C.H. Beck, str. 58
152. Ronka-Chmielowiec, W. (2009). *Ubezpieczenia. Ryzyko i zarządzanie ryzykiem*. Poltext.
153. Ronka-Chmielowiec, W. (2016). *Ubezpieczenia*. Warszawa: Wydawnictwo C.H. Beck.
154. Ronka-Chmielowiec, W. (2017). *Ryzyko ubezpieczeniowe – Współczesne wyzwania dla zakładów ubezpieczeń*. https://dspace.uni.lodz.pl/xmlui/bitstream/handle/11089/22346/%5b117%5d-130_Ronka-Chmielowiec_Ryzyko%20ubezpieczeniowe.pdf?sequence=1&isAllowed=y
155. Ronka-Chmielowiec, W. (2017). *Zarządzanie ryzykiem w ubezpieczeniach komunikacyjnych*. Wydawnictwo Ubezpieczenia.
156. Russell, S., & Norvig, P. (2016). *Artificial Intelligence: A Modern Approach* (3rd ed.). Pearson.
157. Shinar, D. (1998). *Aggressive and risky driving: Psychosocial correlates and driver's characteristics*. Transportation Research Part F: Traffic Psychology and Behaviour, 1(2).

158. Smith, J. (2020). *Advances in Mobile Insurance Technology*. Journal of Insurance Technology, 12(3), 45-67.
159. Sułkowski, Ł. (2021). *Epistemologia, metodologia i metody badań w naukach o zarządzaniu i jakości*. Wydawnictwo Uniwersytetu Łódzkiego.
160. Suzuki, M. (2019). *Leveraging Big Data in Telematics Insurance*. Japanese Journal of Risk and Insurance, 14(3).
161. Szarucki, M. (2020). *Historia i perspektywy nauk o zarządzaniu*. Wydawnictwo Uniwersytetu Ekonomicznego w Krakowie
162. Szymańska, A. (2012). *Wybrane metody szanowania stawek składki netto w ubezpieczeniach komunikacyjnych*. Acta Universitatis Lodzensis Folia Oeconomica 271, 2012.
163. Szymańska, E. (2017). *Zarządzanie ryzykiem w ubezpieczeniach komunikacyjnych*. Polskie Wydawnictwo Ekonomiczne.
164. Taylor, L. (2020). *Innovation in Insurance: The Case of Aviva*. Journal of Financial Services, 28(1).
165. Urząd Ochrony Konkurencji i Konsumentów (2018). *Raport UOKiK o stanie rynku ubezpieczeń komunikacyjnych*.
166. Vaughan, E. J. (1997). *Risk Management*. Wiley.
167. Wąsiewicz, A. (2005). *Podstawy ubezpieczeń. Tom 1. Mechanizmy i funkcje*. Poltext.
168. Wąsiewicz, A. (2005). *Podstawy ubezpieczeń. Tom 1. Mechanizmy i funkcje*. Poltext, str. 56
169. White, D. (2021). *Disrupting the Insurance Market with AI: The Lemonade Example*. Insurance Innovations, 22(5).
170. Wiadomości Ubezpieczeniowe (4) (2017).

Spis rysunków

- Rys. 1.** Graficzna prezentacja ekosystemu koncepcji weryfikacji hipotezy głównej
- Rys. 2.** Przykładowy wynik klasteryzacji zbioru danych algorytmem K-Means w dwóch wymiarach po 13 iteracjach (źródło: Wikipedia https://en.wikipedia.org/wiki/K-means_clustering)
- Rys. 3.** Przykładowy dendrogram zbioru danych po klasteryzacji hierarchicznej (źródło: Wikipedia https://en.wikipedia.org/wiki/Hierarchical_clustering#/media/File:Iris_dendrogram.png)
- Rys. 4.** Schemat przepływu danych w systemach telematycznych (źródło: [https://www.geotab.com/CMS-Media-production/Blog/NA/2021/March/What-is-tel/image3%20\(3\).png](https://www.geotab.com/CMS-Media-production/Blog/NA/2021/March/What-is-tel/image3%20(3).png))
- Rys. 5.** Wyciąg opisu produktowego urządzenia Inssue BOX (źródło: Inssue box_Product Brief, v.2.3, 2019)
- Rys. 6.** Diagram połączeń trackera Inssue BOX. z systemem centralnym
- Rys. 7.** Ramka protokołu komunikacyjnego urządzenia Inssue BOX wer. 2.3. z systemem centralnym
- Rys. 8.** Ogólna przykładowa architektura przetwarzania danych telemetrycznych i uzupełniających (strzałki kropkowane są fakultatywnym zestawem danych)
- Rys. 9.** Przykładowe naklejki z kodem QR urządzenia Inssue BOX wer. 2.3. (źródło: producent urządzeń)
- Rys. 10.** Polski dowód rejestracyjny wraz z danymi zakodowanymi w postaci kodu QR (źródło: <https://www.gov.pl/app/rdp/web/rdp/dowod-rejestracyjny-pojazdu-wzor-2022>)
- Rys. 11.** Koncepcja środowiska prototypowania programu profilera
- Rys. 12.** Koncepcja metody taryfikacji i kwotacji składki
- Rys. 13.** Schematyczna struktura przetwarzania i udostępniania danych i raportów wynikowych
- Rys. 14.** Przykładowa koncepcja architektury docelowego systemu taryfikacji
- Rys. 15.** Uproszczony schemat wyliczania składki ubezpieczeniowej z wykorzystaniem taryfikatora PHYD
- Rys. 16.** Schemat blokowy trackera Inssue BOX wer. 2.3.

- Rys. 17.** HAL i Drivers oprogramowania embedded trakera Inssue BOX wer. 2.3.
- Rys. 18.** Schemat blokowy algorytmów warstwy embedded trakera Inssue BOX wer. 2.3.
- Rys. 19.** Przykładowy raport generowany z systemu Inssue z danych pilotażowych

Spis tabel

Tab. 1. Fazy procesu zarządzania ryzykiem

Tab. 2. Parametry analizy w modelu regresji Poissona

Tab. 3. Specyfikacja wymagań urządzenia Inssue Box

Tab. 4. Pola danych protokołu komunikacyjnego urządzenia Inssue BOX wer. 2.3.

Tab. 5. Współczynniki wagowe taryfikatora T/U/N/RA opartego o sprofilowanie stylu jazdy

Tab. 6. Szczegółowe wymagania Trakera Inssue BOX wer. 2.3.

Tab. 7. Lista kluczowych komponentów trakera Inssue BOX wer. 2.3.

Tab. 8. Wewnętrzne magistrale danych trakera Inssue BOX wer. 2.3.

Tab. 9. Lista głównych wątków programowych w urządzeniu Inssue Box wer. 2.3.

Tab. 10. Zakres i struktura danych wymienianych po magistrali „Inssue BUS”

Załączniki

Załącznik 1 – Wymagania Trakera Inssue BOX wer. 2.3.

Tabela 6


Szczegółowe wymagania Trakera Inssue BOX wer. 2.3.

Kategoria / wymaganie	Opis	Priorytet
1. Niezawodność pracy jednostki		
1.0. Jednostka sygnalizuje stan awarii oraz ostrzeżenia	Urządzenie za pomocą kontrolki LED sygnalizuje status połączenia	Must
1.1. Jednostka wysyła okresowo swój pełny status	Urządzenie wysyła do systemu centralnego komunikat z obszernymi danymi zawierającymi aktualny status i informacje o jego parametrach	Must
1.2. Jednostka wysyła komunikat o błędzie	Urządzenie w momencie zdarzenia typu błąd, ostrzeżenie, wysyła do systemu centralnego komunikat z czasem wystąpienia i szczegółami	Must
1.3. Autodiagnostyka urządzenia	Urządzenie za każdym razem po uruchomieniu oraz cyklicznie wykonuje autodiagnostykę, wynik jest zapisywany w pamięci i wysyłany do systemu centralnego	Should
1.4. Restart automatyczny podzespołu w przypadku wadliwego działania	Jeśli zdiagnozowano problem z podzespołem, urządzenie próbuje wymusić restart podzespołu (np. modemu, modułu GNSS itp.)	Should
1.5. Restart automatyczny urządzenia w przypadku wadliwego działania	Jeśli zdiagnozowano problem krytyczny, urządzenie próbuje uruchomić się ponownie (np. używając funkcjonalności "watchdog")	Must
1.6. Pobranie z serwera domyślnej konfiguracji urządzenia	W przypadku braku możliwości naprawy błędów poprzez procedury resetu, urządzenie pobiera domyślną konfigurację i przyjmuje je jako bieżącą.	Must
1.7. Przywrócenie ustawień fabrycznych	W przypadku braku możliwości naprawy błędów w sposób automatyczny, możliwe jest przywrócenie ustawień fabrycznych	Must
1.8. Jednostka zapisuje informacje o faktach utraty połączenia GSM	Gromadzone są dane do późniejszego przesłania o czasie początku i końcu danej przerwy w połączeniu	Could
1.9. Jednostka zapisuje informacje o faktach utraty połączenia GNSS	Gromadzone są dane do późniejszego przesłania o czasie początku i końcu danej przerwy w połączeniu	Could
2. Aktualizacja oprogramowania		

2.1. Możliwość zdalnej aktualizacji oprogramowania aplikacyjnego (tryb OTA)	Urządzenie łączy się z systemem centralnym, pobiera i aktualizuje swoje oprogramowanie aplikacyjne	Must
2.2. Możliwość zdalnej aktualizacji oprogramowania systemowego (tryb OTA)	Urządzenie łączy się z systemem centralnym, pobiera i aktualizuje swoje oprogramowanie systemowe	Must
2.3. Możliwość zdalnej aktualizacji bootloader'a (tryb OTA)	Urządzenie łączy się z systemem centralnym, pobiera i aktualizuje oprogramowanie bootloader'a	Could
2.4. Możliwość zdalnej aktualizacji jednostki GNSS (tryb OTA)	Urządzenie łączy się z systemem centralnym, pobiera i aktualizuje oprogramowanie dla GNSS	Won't
2.5. Możliwość zdalnej aktualizacji modułu GSM (tryb OTA)	Urządzenie łączy się z systemem centralnym, pobiera i aktualizuje oprogramowanie dla modułu GSM	Won't
2.6. Możliwość zdalnej aktualizacji modułu akcelerometru (tryb OTA)	Urządzenie łączy się z systemem centralnym, pobiera i aktualizuje oprogramowanie dla modułu akcelerometru	Won't
2.7. Możliwość aktualizacji dowolnego modułu oprogramowania w trybie serwisowym	Wgranie oprogramowania w trybie serwisowym za pomocą złącza JTAG	Must
3. Raportowanie statusu		
3.1. Jednostka ma możliwość przekazania w komunikacie swojego numeru seryjnego	Urządzenie wysyła do systemu centralnego komunikat z potrzebną informacją	Must
3.2. Jednostka ma możliwość przekazania w komunikacie informacje o numerach podzespołów (w tym numer IMEI, numer karty SIM itp..)	Urządzenie wysyła do systemu centralnego komunikat z potrzebną informacją	Must
3.3. Jednostka ma możliwość przekazania w komunikacie informacje o wersji oprogramowania jednostki centralnej MCU	Urządzenie wysyła do systemu centralnego komunikat z potrzebną informacją	Must
3.4. Jednostka ma możliwość przekazania w komunikacie informacje o wersji oprogramowania podzespołów	Urządzenie wysyła do systemu centralnego komunikat z potrzebną informacją	Could
3.5. Jednostka sygnalizuje stan połączenia GSM	Urządzenie za pomocą kontrolki LED sygnalizuje status połączenia	Must
3.6. Jednostka sygnalizuje stan połączenia GNSS	Urządzenie za pomocą kontrolki LED sygnalizuje status połączenia	Must
3.7. Jednostka sygnalizuje status procedury uruchomienia po włączeniu zasilania	Urządzenie za pomocą kontrolki LED sygnalizuje status i postęp procedury	Should

3.8. Jednostka sygnalizuje status procedury provisioning'u	Urządzenie za pomocą kontroltek LED sygnalizuje status i postęp procedury	Should
3.9. Jednostka sygnalizuje status procedury OTA Update	Urządzenie za pomocą kontroltek LED sygnalizuje status i postęp procedury	Should
4. Testowanie urządzenia		
4.1. Możliwość przełączania urządzenia pomiędzy trybami normal/debug	W trybie Debug urządzenie zapisuje w pamięci znaczenie więcej informacji niż w trybie Normal, generując tzw. Log'i	Must
4.2. Możliwość odczytywania zapisanych logów za pomocą interfejsu UART	Urządzenie wysyła zapisane dane diagnostyczne poprzez złącze UART	Must
4.3. Możliwość odczytywania informacji o urządzeniu w czasie rzeczywistym za pomocą interfejsu UART	Urządzenie wysyła dane diagnostyczne w czasie rzeczywistym poprzez złącze UART	Could
3.3. Wykonywanie instrukcji wysłanej do urządzenia i przesłanie zwrotnego statusu	Można do urządzenia poprzez UART wysłać kod instrukcji do wykonania wraz z parametrami, a zwrócić odczytać wynik	Should
4.4. Odczyt bufora danych w urządzeniu	Można poprzez UART czytać zawartość bufora	Must
4.5. Czyszczenie bufora danych w urządzeniu	Można poprzez UART wysłać rozkaz wyczyszczenia pamięci bufora	Must
5. Nawiązywanie połączenia GSM/GPRS		
5.1. Urządzenie nawiązuje łączność z siecią GSM	Urządzenie loguje się do sieci (zgodnej z parametrami zapisanymi w karcie SIM)	Must
5.2. Urządzenie inicjuje połączenie dla danych (GPRS)	Urządzenie nawiązuje połączenie do operatora dla transmisji danych	Must
5.3. Urządzenie łączy się z serwerem systemu centralnego	Urządzenie nawiązuje połączenie do systemu centralnego za pomocą odpowiedniego protokołu (TCP/IP, UDP)	Must
5.4. Urządzenie przesyła dane poprzez sieć GSM w czasie rzeczywistym	Stałe połączenie z siecią umożliwiające przesyłanie danych bez opóźnień	Must
5.5. Urządzenie zarządza połączeniem w celu poprawy jakości	Utrzymywanie stabilnego połączenia sieciowego oraz minimalizacja przerw w transmisji danych	Should
5.6. Urządzenie zamyka aktywne połączenie	Zamknięcie połączenia	Must
5.7. Urządzenie wyłącza modem GSM w celu oszczędności zużycia energii	Oszczędzanie zużycia energii w trybie sleep	Could

5.8. urządzenie ma możliwość zmiany operatora na innego, jeśli jego sygnał jest silniejszy	Zmiana operatora	Won't
5.9. Urządzenie obsługuje roaming danych	Roaming danych	Should
5.10. Urządzenie może określić swoją lokalizację za pomocą usług "Mobile Phone Tracking"	Określenie pozycji względem masztów operatora GSM	Could
6. Określanie pozycji z użyciem GNSS		
6.1. Urządzenie odbiera sygnał GNSS z określonych sieci satelitów	Urządzenie odbiera sygnał satelitów	Must
5.2. Moduł wykonuje poprawnie "Cold start"	Urządzenie po włączeniu i identyfikacji sygnału satelitów, pobiera tzw. Almanac dla danej szerokości i długości geograficznej, zapisuje go w swojej pamięci	Must
6.2. Moduł wykonuje poprawnie "Warm start"	Urządzenie po włączeniu i identyfikacji sygnału satelitów, uzupełnia dane satelitów o tzw. Ephemeris data	Must
6.3. Moduł wykonuje poprawnie "Hot start"	Urządzenie po włączeniu i identyfikacji sygnału satelitów, jest gotowe do interpretacji danych i przeliczenia na położenie	Must
6.4. Moduł pracuje w trybie 3D	W celu określenia pozycji 3D (razem z wysokością) wymagany jest odbiór sygnałów z conajmniej 4 satelitów	Must
6.5. Moduł pracuje w trybie 2D	W przypadku pozycji 2D, czwarty pomiar jest przybliżony kalkulacjami, w związku z tym dokładność maleje, często nie da się określić wysokości.	Must
6.6. Moduł jest w stanie zsynchronizować czas i podać czas z dużą dokładnością	Moduł synchronizuje zwraca czas rzeczywisty zgodny z siecią satelitów	Must
6.7. Moduł jest w stanie podać swoje położenie	Moduł zwraca długość i szerokość geograficzną	Must
6.8. Moduł jest w stanie podać swoją wysokość n.p.m.	Moduł zwraca wysokość	Must
6.9. Moduł jest w stanie podać swoją prędkość względną	Moduł zwraca wektor prędkości przemieszczania	Must
6.10. Moduł jest w stanie podać parametry związane z dokładnością pomiaru	Moduł zwraca wielkości HDOP, VDOP, TDOP, URRE i pokrewne	Must
6.11. Urządzenie wyłącza modem GNSS w celu oszczędności zużycia energii	Oszczędzanie zużycia energii w trybie sleep	Could
6.12. obsługa konstelacji satelitarnej GPS (USA)		Must

6.13. obsługa konstelacji satelitarnej GLONASS (Rosja)		Could
6.14. obsługa konstelacji satelitarnej Galileo (Unia Europejska)		Must
6.15. obsługa konstelacji satelitarnej BeiDou (Chiny)		Could
6.16. urządzenie ma możliwość przełączanie pomiędzy różnymi systemami nawigacji satelitarnej, w zależności od widoczności satelity	Zmiana systemu satelitów w celu zwiększenia precyzji	Should
6.17. urządzenie ma możliwość równoczesnego używania kilku systemu satelitów	Równoległe używanie wielu systemu satelitów w celu zwiększenia precyzji	Could
6.18. moduł ma możliwość bezpośredniego podłączenia akcelerometru w celu obsługi "dead reckoning"	Obsługa funkcjonalności "dead reckoning"	Won't
7. Akcelerometr i żyroskop		
7.1. pomiar przyspieszenia liniowego w zakresie do 16 g w osi X	Oś X jest zgodna z kierunkiem ruchu pojazdu, równoległa do powierzchni drogi	Must
7.2. pomiar przyspieszenia liniowego w zakresie do 16 g w osi Y	Oś Y jest poprzeczna do kierunku ruchu pojazdu, równoległa do powierzchni drogi	Must
7.3. pomiar przyspieszenia liniowego w zakresie do 16 g w osi Z	Oś Z jest prostopadłą do powierzchni drogi	Must
7.4. pomiar przyspieszenia kąowego w zakresie do 2000 DPS wokół kąta R	Kąt R oznacza Roll i jest odchyleniem wokół osi X; Kąt Y oznacza Yaw i jest odchyleniem wokół osi Z; Kąt P oznacza Pitch i jest odchyleniem wokół osi Y	Should
7.5. pomiar przyspieszenia kąowego w zakresie do 2000 DPS wokół kąta Y		Should
7.6. pomiar przyspieszenia kąowego w zakresie do 2000 DPS wokół kąta P		Should
7.7. pomiar przyspieszenia liniowego w zakresie High-G (do 100 g) w osi X		Could
7.8. pomiar przyspieszenia liniowego w zakresie High-G (do 100 g) w osi Y		Could
7.9. pomiar przyspieszenia liniowego w zakresie High-G (do 100 g) w osi Z		Could

7.10. Zmiana częstości próbkowania danych	Zmiana parametrów próbkowania	Must
7.11. Zmiana precyzji danych	Zmiana parametrów próbkowania	Must
7.12. Możliwość uśredniania danych w module	Użycie wbudowanych funkcji w ramach jednostki akcelerometru	Must
7.13. Możliwość filtrowania danych za pomocą algorytmów w module	Użycie wbudowanych funkcji w ramach jednostki akcelerometru	Should
7.14. Możliwość użycia algorytmów AI na poziomie modułu	Użycie wbudowanych funkcji w ramach jednostki akcelerometru	Won't
7.15. Algorytm autoorientacji osi akcelerometru względem ramy pojazdu	Dla poprawnego działania potrzebne jest uzyskanie wartości przyspieszeń i prędkości kątowych przeliczonych tak, żeby odpowiadały orientacji pojazdu, a nie orientacji samego trakera. Traker może być obrócony względem osi pojazdu.	Could
8. DSP na poziomie MCU		
8.1. Monitorowanie położenia geograficznego	Zbieranie danych dotyczących położenia	Must
8.2. Monitorowanie prędkości pojazdu	Zbieranie danych dotyczących wektora prędkości (wartość i kierunek)	Must
8.3. Monitorowanie przyspieszania	Zbieranie danych dotyczących przyspieszania i hamowania	Must
8.4. Identyfikacja początku i końca trasy	Algorytm identyfikacji	Could
8.5. Wyliczanie średnich parametrów trasy (czas, długość, średnia prędkość)	Algorytm statystyczny	Could
8.6. Identyfikacja kierowcy	Rozpoznawanie kierowcy na podstawie cech charakterystycznych	Won't
8.7. Rozpoznawanie zdarzenia		
8.7.1. Wykrywanie gwałtownego hamowania	Rejestrowanie nagłych hamowań, co może wskazywać na ryzykowne zachowanie kierowcy	Should
8.7.2. Niebezpieczne pokonywanie zakrętów	Analiza przeciążeń podczas pokonywania zakrętów	Could
8.7.3. Wykrywanie wypadków	Użycie czujników do identyfikacji kolizji	Won't
8.8. Metadane zdarzenia		
8.8.1. Określanie czasu zdarzenia	Zdarzenie powinno mieć sygnaturę czasu (datę, godzinę) z dokładnością do 1 sek.	Must
8.8.2. Określanie pozycji zdarzenia	Zdarzenie ma przypisaną lokalizację miejsca wystąpienia, dokładność minimum 25 m	Must

8.8.3. Określenie prędkości w momencie zdarzenia	Parametr prędkości jest pośrednim kryterium klasyfikacji rodzaju wypadku. Znajomość tej wielkości byłaby pomocna	Must
8.8.4. Określenie kierunku ruchu w momencie zdarzenia	Parametr istotny przy zdarzeniach na autostradzie, aby służby ratownicze wjechały na odpowiedni pas autostrady	Should
8.8.5. Oszacowanie pochłoniętej energii w momencie zdarzenia	Parametr energii jest pośrednim kryterium klasyfikacji rodzaju wypadku. Znajomość tej wielkości byłaby pomocna	Won't
9. Zarządzanie urządzeniami		
9.1. Zbiórce monitorowanie statusu urządzeń	Panel odzwierciedlający status urządzeń w danej grupie użytkowników (np. w grupie pilotażowej)	Must
9.2. Zarządzanie konfiguracją urządzenia z poziomu systemu centralnego	Wysyłanie konfiguracji do zdefiniowanej grupy urządzeń	Should
9.3. Zarządzanie wersją oprogramowania z poziomu systemu centralnego	Wysyłanie aktualizacji do zdefiniowanej grupy urządzeń	Should
9.4. Provisioning urządzenia za pomocą aplikacji mobilnej	Aplikacja wspierająca provisioning	Should
9.5. Zdalna inwentaryzacja urządzeń	Aplikacja wspierająca inwentaryzację	Could
9.6. Zdalne dezaktywowanie i reaktywowanie urządzenia bądź wybranych funkcjonalności		Won't
10. Inne		
9.1. Akwizycja danych uzupełniających dostępnych z pojazdu lub innych urządzeń		
9.1.1. Komunikacja po szynie CAN	np. informacja o zapięciu pasów, włączonych światłach	Could
9.1.2. Komunikacja po szynie OBD-2	np. informacja o prędkości obrotowej silnika, pozycji pedału gazu, poziomie paliwa w zbiorniku	Could
9.1.3. Komunikacja po protokole Bluetooth		Won't
9.2. Komunikacja z komputerem centralnym pojazdu po AAP (Android Auto Protocol)		Won't
9.3. Powiadomianie o zdarzeniach - zgodność ze standardem "e-Call" lub "TPS e-Call"		Could

9.4. Geofencing	Funkcjonalność polegająca na tworzeniu wirtualnych granic w rzeczywistej przestrzeni, którą urządzenia GPS/GNSS mogą wykrywać	
9.4.1. Wykrywanie faktu wjazdu/wyjazdu z danej strefy		Won't
9.4.2. Wykrywanie faktu kradzieży pojazdu		Won't
9.4.3. Tagowanie danych i zdarzeń identyfikatorem strefy		Won't

Załącznik 2 – Szczegóły rozwiązania Trakera Inssue BOX wer. 2.3.

Załącznik 2.1. Architektura wewnętrzna trakera

Konstrukcja urządzenia wynika wprost z przyjętych założeń i oczekiwanej funkcjonalności. Elektronika trakera została zaprojektowana tak, aby urządzenie spełniało wszelkie wymogi bezpieczeństwa zasilania z akumulatora samochodowego oraz pracy w komorze silnika.

Ze względu na tłumienie sygnałów radiowych pod metalową maską komory silnika, konieczne było zastosowanie wysoko czułych anten Bluetooth, GSM oraz GNSS, jak również zastosowanie wzmacniaczy sygnału w torach radiowych.

Główne komponenty elektroniczne zebrano w tabeli 7.


Tabela 7

Lista kluczowych komponentów trakera Inssue BOX wer. 2.3.

Komponent	Opis	Producent / Model
MCU unit	Centralny mikrokontroler 32 bitowy zarządzający pracą, zbieraniem danych, komunikacją oraz przechowywaniem informacji.	ST Microelectronics / STM32 seria L
NAND Flash	Pamięć nieulotna e-MMC do przechowywania danych	Toshiba NAND e-MMC, 512 Mb
SD Host Controller	Kontroler pamięci SD	
SD Card	Karta pamięci SD, umożliwiająca przechowywanie większej ilości danych	Kingston microSDHC, 16 Gb (opcjonalnie)
GSM module	Modem GSM/GPRS do transmisji danych poprzez sieć komórkową	Quectel M66
GNSS module	Odbiornik lokalizacyjny GNSS, który obsługuje GPS, GLONASS, Galileo i BeiDou	ST Microelectronics / Teseo-LIV3
Bluetooth LE module	Modem Bluetooth Low Energy, do łączności z telefonem i innymi urządzeniami kompatybilnymi	(opcjonalny)
RF Circuits	Elementy obwodu toru radiowego, zawierające układy dopasowania, filtry, anteny, wzmacniacze sygnału	Wiele elementów pasywnych i aktywnych różnych producentów
Transceiver CAN	Moduł komunikacyjny z optoizolacją umożliwiający podłączenie do szyny danych CAN pojazdu	(opcjonalny)
Transceiver OBD-2	Moduł komunikacyjny z optoizolacją umożliwiający podłączenie do szyny danych OBD-2 pojazdu	(opcjonalny)
ACC+Gyro	Zintegrowany 6-osiowy bezwładnościowy akcelerometer z żyroskopem, pełniący rolę głównego sensora ruchu	ST Microelectronics / LSM6DSR
High-G ACC	Akcelerometer wysokich przeciążeń, 3-osiowy	ST Microelectronics / H3LIS100

PWR unit	Układ regulacji i sterowania zasilaniem, składający się z zabezpieczeń, przetwornic, filtrów, przełączników i ładowarki ogniwa zewnętrznego	Wiele elementów pasywnych i aktywnych różnych producentów
Backup Battery	Wewnętrzne podtrzymanie zasilania na wypadek chwilowego odłączenia urządzenia od akumulatora pojazdu	Bateria Li-Pol, 2S, 250 mAh
LED panel	LEDy sygnalizujące stan pracy urządzenia	3 różne kolory: Red, Green, Blue

Schemat blokowy urządzenia Inssue Box wer.2.3. zilustrowano na rys. 16.



Rys. 16. Schemat blokowy trakera Inssue BOX ver. 2.3.

Komponenty wewnętrznie komunikują się między sobą za pomocą różnych szyn danych i linii sygnałowych, które udostępnia 32-bitowy mikrokontroler firmy ST Microelectronics, z rodziny ARM (STM32 seria L). Wewnętrzne magistrale danych trakera Inssue przedstawiono w tabeli 8.

Tabela 8

Wewnętrzne magistrale danych trakera Inssue BOX ver. 2.3.


Magistrala	Opis	Podłączone komponenty
UART	Dwukierunkowa uniwersalna magistrala asynchroniczna	GSM Module, GNSS module, Bluetooth module
SPI	Szeregowy interfejs urządzeń peryferyjnych	ACC+Gyro, High-G ACC
I2C	Szeregowy interfejs urządzeń peryferyjnych	Pamięć NAND Flash i SD
JTAG	Interfejs programistyczno-testowy	Programator zewnętrzny
GPIO	Uniwersalne linie sygnałowe, wejście lub wyjście	Sterowanie zasilaniem, sterowanie diodami LED

Inne komponenty wybrano też głównie firmy ST Microelectronics, aby zachować jak największą wzajemną kompatybilność.

Załącznik 2.2. Opis kluczowych algorytmów w warstwie embedded

Oprogramowanie trakera zostało stworzone na wspomniany STM32. Oprogramowanie zostało napisane w języku C, z wykorzystaniem wysokopoziomowej warstwy abstrakcji HAL (Hardware Abstraction Layer) oraz sterowników (Drivers) dostarczanych przez producentów komponentów.


Każda jednostka funkcjonalna bądź urządzenie peryferyjne ma swój odpowiednik programistyczny w postaci modułu w warstwie HAL oraz odpowiedni sterownik i bibliotekę do jego obsługi. Ilustruje to rysunek 17.



Rys 17. HAL i Drivers oprogramowania embedded trakera Inssue BOX ver. 2.3.

Rysunek 18 przedstawia schemat blokowy głównych algorytmów pracujących autonomicznie w każdym trackerze. Po podłączeniu zasilania do trakera następuje uruchomienie programu przechowywanego w pamięci nieulotnej urządzenia. Pierwszym krokiem jest właśnie inicjalizacja wspomnianych jednostek funkcjonalnych i urządzeń peryferyjnych, w procedurze „Initialize device”.

Kolejnym krokiem jest wykonanie serii autotestów, zdefiniowanych w procedurze „Autotest procedure”. Jeśli nie powiedzie się uruchomienie jakiegoś podzespołu, urządzenie zresetuje podzespół i uruchomi go ponownie.



Rys. 5. Schemat blokowy algorytmów
warstwy embedded trakera Inssue BOX v.3.0

Rys. 18. Schemat blokowy algorytmów warstwy embedded trakera Inssue BOX wer. 2.3.

Po poprawnym uruchomieniu wszystkich podzespołów, urządzenie nawiązuje połączenie z serwisem autentykacji („Connect to Authentication Service”), aby sprawdzić czy urządzenie jest zarejestrowane w systemie, czy posiada ważne klucze szyfrujące dane („Certificate and Key Exchange”). Wysyła też informacje z wynikiem przeprowadzonych testów („Send status and autotest result”), aby system centralny miał informacje, czy urządzenie działa poprawnie. Następnie urządzenie uruchamia równolegle kilka wątków („Threads”), a w tzw. pętli głównej („Main Loop”) przystępuje do zbierania pomiarów i wysyłania danych telematycznych.

Należy zwrócić uwagę, że urządzenie ma zaimplementowaną maszynę stanów:

- stan: „Car stopped” – pojazd nie porusza się, nie ma potrzeby zbierania i analizowania danych, urządzenie przechodzi w tryb „Low-power mode”, usypiając jednostkę MCU.
- stan: „Car moved” – pojazd porusza się, urządzenie jest w trybie „Normal-power mode”, podczas którego w pętli głównej dokonywana jest akwizycja, analiza danych oraz wysyłka danych telemetrycznych.

Występują jeszcze stany specjalne, podczas których są podejmowane działania specjalne:

- stan: „Hardware error occurred” – w przypadku błędu urządzenia, podejmowana jest próba jego zrestartowania
- stan: „OTAU in progress” – urządzenie ściąga aktualizację z serwera i dopóki nie zakończy procedury OTAU („Over the Air Update”) nie wykonuje się pętla główna.

Tabela 9

Lista głównych wątków programowych w urządzeniu Inssue Box wer. 2.3.

Wątek	Opis
Monitor vehicle movement	Na podstawie danych z akcelerometru, modułu GNSS i ewentualnie innych sygnałów (np. „Ignition” z magistrali OBD-2), rozpoznawany jest stan pojazdu. Wątek steruje maszyną stanów, przypisując urządzeniu odpowiednio stany: – Car stopped – Car moved
Monitor health device	Monitorowany jest stan urządzeń peryferyjnych. W przypadku wystąpienia błędu wysyłana jest informacja o błędzie do systemu centralnego, a urządzenie podejmuje próbę naprawy problemu poprzez wymuszenie resetu i restartu oprogramowania. Wątek przełącza podczas tej procedury stan urządzenia na: – Hardware error occurred

OTA Update	Wątek przeprowadza aktualizację oprogramowania. Urządzenie łączy się co najmniej 1 raz na dobę z odpowiednim endpoint'em, skąd pobiera informacje, czy jest dostępna aktualizacja oprogramowania. Jeśli jest dostępna nowa wersja, to ją ściąga z serwera na urządzenie i przeprowadza jego aktualizację. Po poprawnym wykonaniu procedury następuje reset i restart urządzenia, tracker zaczyna działać już na nowym oprogramowaniu.
Main loop	W pętli głównej są wykonywane cyklicznie następujące algorytmy: – pobrania danych z urządzeń peryferyjnych (akcelerometr, żyroskop, GNSS, inne) z adekwatną częstotliwością próbkowania, – przetwarzania danych (np. filtrowanie, uśrednianie), – tagowania danych timestamp'em, (czas jest przy okazji synchronizowany z satelitami GNSS) – łączenia danych w paczki, – składowania danych w buforze i pamięci urządzenia (w razie braku miejsca na karcie SD), – nawiązywania połączenia z endpoint'em telematyki, – wysyłki danych z bufora.
Watchdog	To wbudowany mechanizm, którego zadaniem jest przywrócenie systemu do działania po zawieszeniu programu. Jest to timer, który zlicza od zadanej wielkości w dół. W momencie, kiedy dojdzie do zera, powoduje reset MPU. Aby uniknąć resetu wątek główny co pewien czas powinna ustawiać timer z powrotem na początkową wartość (tzw. „feeding”).

Załącznik 3 – Zakres i struktura danych wymienianych w systemie Inssue Flota

Tabela 10

Zakres i struktura danych wymienianych po magistrali „Inssue BUS”

Opis danych			Pilotaż	Rozwiązanie docelowe
Grupa / Zakres danych	Typ danych	Cel wykorzystania danych	U - used, N - no, O - optional, F - for future use	
Kierowca				
Driver ID (identyfikator kierowcy)	dane podstawowe ubezpieczonego	powiązanie kierowcy (ubezpieczonego) z pojazdem	U	U
Imię i nazwisko	dane podstawowe ubezpieczonego	w celu potwierdzenia tożsamości	O	U
Wiek	dane podstawowe ubezpieczonego	w celach statystycznych (np. ryzyko wypadku zależne od wieku kierowcy)	N	U
Telefon kontaktowy	dane podstawowe ubezpieczonego	w celu potwierdzenia zdarzenia (kontakt telefoniczny), w celu wysyłania informacji (sms)	U	U
Mail kontaktowy	dane podstawowe ubezpieczonego	w celach informacyjnych (np. wysyłka raportu) oraz kontaktowyhc (zapytanie o feedback)	N	F
Pojazd				
Car ID (identyfikator pojazdu)	dane podstawowe pojazdu	do powiązania pojazdu z urządzeniem (zakładamy, że jeden pojazd ma jedno urządzenie)	U	U
Nr rejestracyjny	dane podstawowe pojazdu	używane w raportach	U	U
Marka	dane podstawowe pojazdu	używane w raportach oraz statystykach	O	O
Model	dane podstawowe pojazdu	używane w raportach oraz statystykach	O	O
Waga własna pojazdu	dane podstawowe pojazdu	używane w analityce (niektóre obliczenia mogą być zależne od masy pojazdu)	N	U
Rok produkcji	dane podstawowe pojazdu	w celach statystycznych (np. ryzyko wypadku zależne od wieku pojazdu)	N	O

Przebieg	dane podstawowe pojazdu	w celach statystycznych (np. ryzyko wypadku zależne od przebiegu)	N	F
Inne dane z dowodu rejestracyjnego				
pierwsza data rejestracji,	dane podstawowe pojazdu	zbudowanie taryfy ubezpieczeniowej (ceny za polisę)	N	F
dane dotyczące właściciela	dane podstawowe pojazdu	zbudowanie taryfy ubezpieczeniowej (ceny za polisę)	N	F
przeznaczenie pojazdu	dane podstawowe pojazdu	zbudowanie taryfy ubezpieczeniowej (ceny za polisę)	N	F
rodzaj paliwa	dane podstawowe pojazdu	zbudowanie taryfy ubezpieczeniowej (ceny za polisę)	N	F
pojemność i moc silnika	dane podstawowe pojazdu	zbudowanie taryfy ubezpieczeniowej (ceny za polisę)	N	U
nr nadwozia VIN	dane podstawowe pojazdu	zbudowanie taryfy ubezpieczeniowej (ceny za polisę)	N	F
rodzaj pojazdu	dane podstawowe pojazdu	zbudowanie taryfy ubezpieczeniowej (ceny za polisę)	N	U
nr karty pojazdu	dane podstawowe pojazdu	zbudowanie taryfy ubezpieczeniowej (ceny za polisę)	N	F
homologacja (jeżeli występuje)	dane podstawowe pojazdu	zbudowanie taryfy ubezpieczeniowej (ceny za polisę)	N	F
liczba osi - przy ciężarówkach	dane podstawowe pojazdu	zbudowanie taryfy ubezpieczeniowej (ceny za polisę)	N	F
maksymalna masa całkowita przyczepy z hamulcem	dane podstawowe pojazdu	zbudowanie taryfy ubezpieczeniowej (ceny za polisę)	N	F
maksymalna masa całkowita przyczepy bez hamulca	dane podstawowe pojazdu	zbudowanie taryfy ubezpieczeniowej (ceny za polisę)	N	F
Dane polisy				
Ubezpieczyciel	dane podstawowe polisy	do celu wyliczenia składki ubezpieczenia	N	F
Numer polisy	dane podstawowe polisy	do celu wyliczenia składki ubezpieczenia	N	F
Rodzaj polisy	dane podstawowe polisy	do celu wyliczenia składki ubezpieczenia	N	F
Data rozpoczęcia okresu ubezpieczenia	dane podstawowe polisy	do celu wyliczenia składki ubezpieczenia	N	F
Data zakończenia okresu ubezpieczenia	dane podstawowe polisy	do celu wyliczenia składki ubezpieczenia	N	F
Zakres ubezpieczenia: w tym	dane podstawowe polisy	do celów sprzedażowych	N	F
OC	dane podstawowe polisy	do celów sprzedażowych	N	F
AC	dane podstawowe polisy	do celów sprzedażowych	N	F
NNW	dane podstawowe polisy	do celów sprzedażowych	N	F

Assistance	dane podstawowe polisy	do celów sprzedażowych	N	F
Dodatkowe ubez. (jak opony, szyby)	dane podstawowe polisy	do celów sprzedażowych	N	F
Odpowiedzialność prawna - do ustalenia zakres	dane podstawowe polisy	do celów sprzedażowych	N	F
Urządzenie				
DeviceSN (serial number)	dane podstawowe urządzenia	identyfikacja urządzenia, z którego przyszły dane	U	U
ICCID	dane podstawowe urządzenia	numer karty SIM w urządzeniu, potrzebny do zarządzania kartami SIM	U	U
Orientacja względem ramy pojazdu	dane podstawowe urządzenia	potrzebne do zorientowania osi akcelerometru względem ramy pojazdu	U	U
MainPcbSN, PowerSupplySN, BatterySN, BatchSN	dane podstawowe urządzenia	numery składowe komponentów	U	U
IMEI	dane podstawowe urządzenia	numer modemu w urządzeniu, potrzebny do identyfikacji źródła danych	U	U
SIM	dane podstawowe urządzenia		U	U
PIN	dane podstawowe urządzenia	numer PIN karty SIM, potrzebny do zarządzania kartami SIM	U	U
Phone	dane podstawowe urządzenia		U	U
OperatorID	dane podstawowe urządzenia		U	U
MSISDN	dane podstawowe urządzenia	numer abonencki karty SIM, potrzebny do zarządzania kartami SIM	U	U
Active	dane podstawowe urządzenia	informuje czy urządzenie jest aktywne	U	U
Model	dane podstawowe urządzenia	model urządzenia, potrzebne do celów ewidencji oraz świadczenia serwisu gwarancyjnego	U	U
Version	dane podstawowe urządzenia	wersja urządzenia, potrzebne do celów ewidencji oraz świadczenia serwisu gwarancyjnego	U	U
Hardware version	dane podstawowe urządzenia	zarządzanie urządzeniem	U	U
Software version	serwer konfiguracji	zarządzanie urządzeniem	U	U
Konfiguracja urządzenia	serwer konfiguracji	zarządzanie urządzeniem	U	U

Dane diagnostyczne urządzenia (co najmniej 1 / 24h)				
Uptime	pakiet danych wysłany z urządzenia	monitoring poprawności działania urządzenia	U	U
Wersja sprzętowa	pakiet danych wysłany z urządzenia	monitoring poprawności działania urządzenia	U	U
Pełna wersja urządzenia (wliczając datę i czas utworzenia)	pakiet danych wysłany z urządzenia	monitoring poprawności działania urządzenia	U	U
Czas zegara urządzenia	pakiet danych wysłany z urządzenia	monitoring poprawności działania urządzenia	U	U
Ilość widzanych i użytych satelit, stan GPS fix	pakiet danych wysłany z urządzenia	monitoring poprawności działania urządzenia	U	U
RSSI GSM	pakiet danych wysłany z urządzenia	monitoring poprawności działania urządzenia	U	U
Stan połączenia z serwerem, ilość przesłanych danych	pakiet danych wysłany z urządzenia	monitoring poprawności działania urządzenia	U	U
Ilość zaległych danych do wysłania, ilość wolnej pamięci	pakiet danych wysłany z urządzenia	monitoring poprawności działania urządzenia	U	U
Ilość wybudzeń urządzenia z powodu ruchu	pakiet danych wysłany z urządzenia	monitoring poprawności działania urządzenia	U	U
Stan algorytmu detekcji ruchu samochodu, czas bezruchu	pakiet danych wysłany z urządzenia	monitoring poprawności działania urządzenia	U	U
Ilość zgłoszonych błędów	pakiet danych wysłany z urządzenia	monitoring poprawności działania urządzenia	U	U
Treść niektórych błędów	pakiet danych wysłany z urządzenia	monitoring poprawności działania urządzenia	U	U
Ilość resetów systemowych	pakiet danych wysłany z urządzenia	monitoring poprawności działania urządzenia	U	U
Temperatura wewnętrzna urządzenia	pakiet danych wysłany z urządzenia	monitoring poprawności działania urządzenia	U	U
Napięcie wejściowe (bateria lub akumulator)	pakiet danych wysłany z urządzenia	monitoring poprawności działania urządzenia	U	U

Telemetria				
Timestamp	pakiet danych wysłany z urządzenia	data i czas zdarzenia albo pomiaru (synchronizowany z czasem GSM)	U	U
Pozycja geograficzna (GNSS, triangulacja GSM)	pakiet danych wysłany z urządzenia	lokalizacja pojazdu podczas pomiaru lub zdarzenia	U	U
Wysokość nad poziomem morza	pakiet danych wysłany z urządzenia	lokalizacja pojazdu podczas pomiaru lub zdarzenia	N	F
Prędkość pojazdu (GNSS)	pakiet danych wysłany z urządzenia	do analizy zdarzenia albo stylu jazdy, identyfikacja przekroczeń prędkości	U	U
Przyspieszenie w 3 osiach (Low-g: do 16g)	pakiet danych wysłany z urządzenia	do analizy zdarzenia albo stylu jazdy	U	U
Przyspieszenie w 3 osiach (High-g: do 100 g)	pakiet danych wysłany z urządzenia	do analizy zdarzenia albo stylu jazdy	U	U
Przyspieszenie kątowe w 3 osiach (żyroskop)	pakiet danych wysłany z urządzenia	do analizy zdarzenia albo stylu jazdy	N	F
Preprocessing				
Dopasowanie pozycji do drogi	HERE Maps	dana kontrolna	U	U
Ograniczenie prędkości w danym miejscu	HERE Maps	identyfikacja przekroczeń prędkości	U	U
Naruszenia przepisów drogowych (np. przekroczenie prędkości, inne)	HERE Maps + procesowanie danych	ustalenie skali naruszeń	U	U
Rodzaj drogi (autostady, drogi szybkiego ruchu, drogi krajowe, gminne...)	HERE Maps	statystyki	U	U
Klasyfikacja teren zabudowany/niezabudowany	HERE Maps	statystyki, identyfikacja przekroczeń prędkości	U	U
Pora dnia (dzień/noc)	Algorytm astronomiczny	statystyki, identyfikacja przekroczeń dopuszczalnego czasu jazdy	U	U
Crash detection				
Czas zdarzenia	pakiet danych wysłany z urządzenia	obsługa zdarzenia potencjalnie wypadkowego	U	U

Identyfikator urządzenia	pakiet danych wysłany z urządzenia	obsługa zdarzenia potencjalnie wypadkowego	U	U
Identyfikator pojazdu	komponenty wewnętrzne systemu	obsługa zdarzenia potencjalnie wypadkowego	U	U
Pozycja geograficzna pojazdu w trakcie zdarzenia	pakiet danych wysłany z urządzenia	obsługa zdarzenia potencjalnie wypadkowego	U	U
Kwalifikacja typu zdarzenia (wypadek, inne zdarzenia)	procesowanie danych	obsługa zdarzenia potencjalnie wypadkowego	U	U
Kwalifikacja siły zdarzenia (wypadek ciężki, ... , stłuczka)	procesowanie danych	obsługa zdarzenia potencjalnie wypadkowego	U	U
Status obsługi zdarzenia	procesowanie danych	obsługa zdarzenia potencjalnie wypadkowego	U	U
Identyfikator kierowcy	komponenty wewnętrzne systemu	obsługa zdarzenia potencjalnie wypadkowego	U	U
Wnioskowanie o przebiegi zdarzenia	procesowanie danych (off-line)	obsługa zdarzenia potencjalnie wypadkowego	U	U
Inne				
Pogoda w danym miejscu i czasie	systemy zewnętrzne (API)	Powiązanie zdarzenia z warunkami atmosferycznymi	N	F
Informacja o korkach i utrudnieniach	systemy zewnętrzne (API)	Powiązanie zdarzenia z sytuacją na drodze	N	F
Warunki oświetleniowe	algorytm astronomiczny	Powiązanie zdarzenia z warunkami oświetleniowymi	N	O

Załącznik 4 – Przykładowy raport generowany z systemu Inssue z danych pilotażowych



Raport analityczny

sposobu jazdy i eksploatacji pojazdu

Okres: 2019.02.01 - 2019.02.03

Raport: dzienny

Data wydruku: 2019-02-12 13:30


Nr rejestracyjny: 352093084589901

Marka/model: Opel


Numer rejestratora: 352093084589901

LICZBA PRZEJAZDÓW


Przejazdy dzienne/nocne/mieszane




Przejazdy długie/średnie/krótkie




Rozkład długości przejazdów



Przejazdy: Dni tygodnia



Przejazdy: Godzinne




DŁUGOŚĆ I CZAS PRZEJAZDÓW


Przejazdy

Suma	Średnio	Maksymalny
788,4 km	71,7 km	327,1 km
11:06 h	01:01 h	03:54 h


Teren zabudowany/niezabudowany




Kategorie dróg




Dzień/noc




Dni tygodnia - suma



Dni tygodnia - średnia/maksimum



Przejazdy/Parkowanie




Parkowanie
Suma
60:54 h
Średnia
05:05 h

PRĘDKOŚĆ

Prędkość wg obszarów i rodzajów dróg

	teren			typ drogi					
	ogólnie	zabudow.	niezabudow.	autostrada	ekspresowa	krajowa	wojewódz.	powiatowa	nieklasyfik.
Max	191	160	191	156	191	173	115	0	115
Śr.	71,03	36,23	105,20	105,83	131,71	55,86	52,31	0,00	31,78


Histogram prędkości




Przekroczenia prędkości

	teren			typ drogi					
	ogólnie	zabudow.	niezabudow.	autostrada	ekspresowa	krajowa	wojewódz.	powiatowa	niesklasyfik.
Max	102	70	102	41	87	102	57	0	-

Histogram przekroczeń prędkości



Procent przekroczeń prędkości



Streszczenie

Celem niniejszej pracy doktorskiej było opracowanie innowacyjnej metody taryfikacji i kwotacji składek ubezpieczeniowych w oparciu o dane telemetryczne oraz algorytmy sztucznej inteligencji (AI). Tradycyjne metody taryfikacji w sektorze ubezpieczeń komunikacyjnych opierają się głównie na danych statycznych i historycznych, co często prowadzi do niedokładnej oceny ryzyka. W odpowiedzi na te wyzwania zaproponowano nowoczesne rozwiązanie wykorzystujące technologie Internetu Rzeczy (IoT) oraz zaawansowane modele AI, umożliwiające dynamiczną i precyzyjną ocenę ryzyka.

Praca została podzielona na pięć głównych rozdziałów. W Rozdziale I przedstawiono teoretyczne podstawy procesu taryfikacji i kwotacji składek ubezpieczeniowych, identyfikując kluczowe problemy tradycyjnych podejść. Rozdział II omówił nowoczesne technologie komunikacji zdalnej, w szczególności IoT i AI, które mają potencjał do usprawnienia procesów taryfikacyjnych.

Rozdział III skoncentrował się na metodyce prowadzonych badań, prezentując szczegółowo zastosowaną metodykę badawczą, w tym wykorzystanie podejścia Design Science Research (DSR) oraz narzędzi analitycznych opartych na AI i IoT w celu zbadania efektywności opracowanej metody taryfikacji.

Rozdział IV przedstawił opracowaną metodę taryfikacji i kwotacji składek, opartą na zbieraniu rzeczywistych danych telemetrycznych z pojazdów oraz ich analizie za pomocą algorytmów AI, takich jak las losowy (Random Forest), sieci neuronowe (Deep Neural Networks), metoda k-średnich (k-means) i k-najbliższych sąsiadów (k-NN), aby przetworzyć zebrane dane i stworzyć precyzyjne profile ryzyka kierowców.

Rozdział V zaprezentował wyniki eksperymentów przeprowadzonych w firmie Krakchemia S.A. Badania na flotyli pojazdów potwierdziły, że proponowana metoda umożliwia bardziej precyzyjną ocenę ryzyka, co pozwoliło na obniżenie składek ubezpieczeniowych o 20%. Jednym z najważniejszych rezultatów było opracowanie algorytmu crash detection, który pozwala na automatyczne wykrywanie zdarzeń drogowych i proaktywną reakcję zakładu ubezpieczeń w ramach usług assistance.

Przeprowadzone badania potwierdziły, że cel główny pracy został zrealizowany, a zaproponowana metoda taryfikacji i kwotacji składek ubezpieczeniowych znacząco usprawnia proces oceny ryzyka, umożliwiając bardziej dynamiczną i precyzyjną taryfikację. Praca wniosła istotny wkład w dziedzinę zarządzania

ryzykiem w ubezpieczeniach komunikacyjnych, łącząc w praktyce zaawansowane technologie komunikacji zdalnej i AI.

Ograniczenia badań obejmowały ograniczoną skalę eksperymentu (floty 20 pojazdów) oraz konieczność symulowania pewnych warunków drogowych. W przyszłości proponuje się rozszerzenie badań na większą skalę oraz integrację dodatkowych źródeł danych, takich jak prognozy pogodowe czy analizy geolokalizacyjne, w celu dalszego zwiększenia precyzji oceny ryzyka.

Abstract

The aim of this doctoral dissertation was to develop an innovative method for insurance premium tariffing and quoting based on telemetry data and artificial intelligence (AI) algorithms. Traditional tariffing methods in the motor insurance sector rely primarily on static and historical data, which often leads to inaccurate risk assessment. In response to these challenges, a modern solution was proposed, leveraging the Internet of Things (IoT) technology and advanced AI models, enabling dynamic and precise risk evaluation.

The dissertation is divided into five main chapters. Chapter I presents the theoretical foundations of the insurance premium tariffing and quoting process, identifying key problems in traditional approaches. Chapter II discusses modern remote communication technologies, particularly IoT and AI, which have the potential to enhance the tariffing process.

Chapter III focuses on the methodology of the conducted research, detailing the applied research methods, including the use of Design Science Research (DSR) and analytical tools based on AI and IoT, to examine the effectiveness of the developed tariffing method.

Chapter IV introduced the developed method for insurance premium tariffing and quoting, based on collecting real telemetry data from vehicles and analyzing it using AI algorithms, such as Random Forest, Deep Neural Networks, k-means clustering, and k-Nearest Neighbors (k-NN), to process the data and create accurate risk profiles for drivers.

Chapter V presented the results of experiments conducted in the Krakchemia S.A. company. The studies involving a fleet of vehicles confirmed that the proposed method enables a more accurate risk assessment, resulting in a 20% reduction in insurance

premiums. One of the most significant outcomes was the development of a crash detection algorithm, which allows for automatic detection of road incidents and proactive insurer response within assistance services.

The conducted research confirmed that the main objective of the dissertation was achieved, and the proposed method for insurance premium tariffing and quoting significantly improves the risk assessment process, enabling a more dynamic and precise tariffing approach. The dissertation made a significant contribution to the field of risk management in motor insurance by practically combining advanced remote communication technologies with AI.

The limitations of the study included the limited scale of the experiment (a fleet of 20 vehicles) and the need to simulate certain road conditions. Future research should focus on extending the study to a larger scale and integrating additional data sources, such as weather forecasts or geolocation analyses, to further enhance the precision of risk assessment.