

Streszczenie

Tytuł: Forecasting prices for road freight transport services using machine learning"

Niniejsza praca doktorska koncentruje się na opracowaniu nowej metody prognozowania cen w drogowym transporcie towarów, opartej na narzędziach uczenia maszynowego i kompleksowej analizie danych. Przyjęte podejście obejmowało gromadzenie, transformację oraz weryfikację informacji pochodzących z ofert transportowych, zintegrowanych z bazami zewnętrznymi (m.in. ceny paliw, opłaty drogowe, liczba zarejestrowanych naczep czy dane makroekonomiczne). Analiza wykazała, że dystans pozostaje głównym czynnikiem wpływającym na cenę, lecz istotną rolę odgrywają również dane historyczne dotyczące konkretnych relacji, dodatkowe koszty (np. promowe czy tunelowe) oraz wybrane cechy operacyjne, takie jak typ pojazdu czy rodzaj naczepy.

Zastosowane algorytmy pozwoliły osiągnąć istotnie niższy błąd prognozy (MAPE) niż tradycyjne procedury i wyceny eksperckie (9,28% wobec 11,86%). Włączanie zewnętrznych baz danych (cen paliw, opłat drogowych i liczby naczep) dodatkowo obniżyło błąd predykcji (m.in. do 7,90% dla najlepszego modelu). Przeprowadzone badania obejmowały ponad 45 tys. rekordów, a stabilność uzyskanych rezultatów potwierdzono poprzez różne formy walidacji (m.in. krzyżową i opartą na podziale czasowym). Metodyka, obejmująca szczegółowe techniki czyszczenia i normalizacji danych, inżynierię cech oraz testowanie modeli, może zostać skutecznie przeniesiona na inne rynki i segmenty transportu. Dodatkowo zaproponowano możliwości wdrożenia uzyskanych wyników w przedsiębiorstwach logistyczno-spedycyjnych i podczas kształcenia przyszłych specjalistów.

W ramach pracy powstała nowa metoda prognozowania cen drogowego transportu towarów z wykorzystaniem uczenia maszynowego, której skuteczność potwierdzono, osiągając dla modelu błąd prognozy (MAPE) na poziomie 9,28% w porównaniu do 11,86% uzyskanych przez ekspertów. W badaniach zestawiono różne algorytmy uczenia maszynowego i stwierdzono, że sześć z nich pozwala zachować średni błąd poniżej 10%. Zaproponowano rozwiązania umożliwiające dołączenie baz zewnętrznych (paliwowych, z danymi o opłatach drogowych, liczbie naczep i PKB), co istotnie poprawiło rezultaty modeli – zwłaszcza przy jednoczesnym uwzględnieniu paliw, opłat drogowych i liczby naczep. Najlepszy wariant obniżył błąd z 8,11% do 7,90%. Opracowane procedury mogą znaleźć zastosowanie zarówno w działalności różnego typu przedsiębiorstw transportowych, jak i w procesie edukacyjnym. Wnioski dowodzą, że implementacja uczenia maszynowego w wycenie usług drogowego transportu towarów nie tylko podnosi trafność prognoz, lecz także przynosi znaczące oszczędności operacyjne.