


Optymalizacja rozpuszczalności gazu Henry'ego za pomocą funkcji głębokiego uczenia się Prognozowanie przepływu ruchu w sieciach kołowych obsługujących technologię 6G

Wstęp

Ciągły postęp w kierunku techniki transmisji bezprzewodowej 6G pokonuje rygorystyczne ograniczenia w zakresie obliczeń, przechowywania, zasilania i prywatności, tworząc inteligentny i wydajny system transportu nowej generacji, poprawiający wrażenia z jazdy i łagodzący korki w kołowych sieciach ad hoc (VANET). Wraz z techniką 6G, VANET zapewnia wyższą przepustowość, wyższą dostępność i wyższą niezawodność. Dzięki poprawie infrastruktury i wzrostowi gospodarczemu praca i życie ludzi nie ograniczają się do jednego miasta. Działalność społeczna związana z wieloma miastami stała się niezbędnym warunkiem naszego codziennego życia. Podobnie jak połączenie dwóch miast, autostrady z pewnością odgrywają ważną rolę w naszym codziennym życiu i pracy. Kiedy droga jest okazjonalnie zamknięta lub z powodu złych warunków pogodowych lub wypadku na autostradzie powstają korki, poważnie wpływa to na pracę lub plany podróży ludzi. Podobnie jak metoda nadzoru ruchu, technika przewidywania przepływu ruchu na autostradach może pomóc odpowiednim departamentom i rządowi w kierowaniu pojazdami w celu uniknięcia zatorów w ruchu oraz w planowaniu dróg. Ponieważ metoda przewidywania ruchu na autostradzie ma cechy przestrzenne i czasowe, na które wpływa również czynnik zewnętrzny, głównym problemem napotykanym przy przewidywaniu natężenia ruchu w punktach poboru opłat autostradowych jest nieodpowiednie uwzględnienie czynników wpływających. Rysunek ilustruje infrastrukturę VANET.



Grupowanie elementów przestrzennych i czasowych można nazwać cechami czasoprzestrzennymi. Czynnik zewnętrzny obejmuje typ daty i warunki pogodowe. Na przykład ludzie są lepiej przygotowani do wyjazdu w podróż przy dobrej pogodzie. Szczególnie w weekendy i święta gwałtownie wzrasta zapotrzebowanie na osoby lubiące podróże. Dlatego też efektywne wykorzystanie tego czynnika na podstawie informacji z przeszłości stało się głównym zadaniem przewidywania przepływu ruchu na autostradach. Rzeczywiście, krótkoterminowe przewidywanie przepływu ruchu opiera się głównie na aktualnych i historycznych informacjach o ruchu gromadzonych przez różne węzły czujników (na przykład radar, cewki indukcyjne, media społecznościowe, kamery i mobilne systemy globalnego pozycjonowania) w celu budowania odpowiednich algorytmów i modeli. Ze względu na zasady obecne krótkoterminowe modele predykcyjne przepływu ruchu są szeroko podzielone na podejścia

symulacyjne, metody parametryczne i metody nieparametryczne. Bhatia i in. przedstawili opartą na danych metodę wdrożenia metody sztucznej inteligencji do prognozowania zachowań w ruchu kołowym. Następnie zintegrowali możliwości adaptacji, elastyczność i skalowalność wykorzystywane przez platformę sieci kołowej definiowanej programowo (SDVN) i podejście do uczenia maszynowego (ML) w celu wydajnego modelowania przepływu ruchu. Następnie skonstruowano strukturę sieci neuronowej z pamięcią długoterminową (LSTM-NN), która rozwiązuje problem zanikania błędów propagowanych wstecznie poprzez blok pamięci na potrzeby modelu predykcyjnego ruchu czasoprzestrzennego wykorzystującego wyższą zależność czasową. Zhao i in. [9] przedstawili metodę przewidywania wypadków drogowych opartą na spłotowej sieci neuronowej (CNN). Podejście DL mogłoby wyodrębnić autonomiczne funkcje z ogromnej liczby informacji zgromadzonych w VANET. Odrębne jądra spłotowe są odpowiedzialne za wyodrębnianie odrębnych cech, a osiągnięte nowe parametry są wprowadzane do wytrenowanego modelu z serwera obliczeń brzegowych w celu testowania i szkolenia. Zaproponowali scentralizowany system routingu wykorzystujący prognozę mobilności do VANET wspomaganą przez sieć determinowaną programowo (SDN) sterowaną sztuczną inteligencją. W szczególności kontroler SDN mógłby wdrożyć precyzyjną metodę przewidywania mobilności przy użyciu innowacyjnej metody sztucznej sieci neuronowej (ANN). Następnie, w zależności od systemu przewidywania mobilności, oceniana jest efektywna możliwość komunikacji i normalne opóźnienie każdego żądania pojazdu w przypadku typowych zmian topologii sieci. Tong i inni wykorzystują optymalizację regresji wektora nośnego (SVM) jako metodę przewidywania przepływu ruchu. Optymalizację roju cząstek zastosowano w celu zoptymalizowania parametrów regresora wektora nośnego (SVR), co zwiększa efektywność metody predykcyjnej. W tym badaniu opracowano nowatorską optymalizację rozpuszczalności gazów Henry'ego za pomocą techniki prognozowania przepływu ruchu z obsługą głębokiego uczenia się (HGSODL-TFF) dla sieci kołowych obsługujących 6G. Zaprezentowana technika HGSODLTFF ma przede wszystkim na celu prognozowanie poziomu ruchu w sieci VANET z obsługą 6G. Ponadto model HGSODL-TFF początkowo wstępnie przetwarza dane o ruchu, stosując podejście normalizacji z-score. Poza tym do skutecznego prognozowania przepływu ruchu wykorzystywany jest model sieci głębokich przekonań (DBN). Algorytm HSGO można również zastosować do optymalnej modyfikacji hiperparametrów (takich jak szybkość uczenia się, liczba epok i wielkość partii) modelu DBN, poprawiając w ten sposób wydajność prognozowania. Eksperymentalna walidacja modelu HGSODL-TFF jest przeprowadzana na danych testowych, a wyniki są sprawdzane pod kilkoma względami.

Proponowany model

W tym badaniu opracowano nową technikę HGSODL-TFF do przewidywania przepływu ruchu w sieci VANET wspomaganą przez sieć 6G. Prezentowany model HGSODL-TFF obejmuje trzy różne procesy, takie jak przetwarzanie wstępne, przewidywanie oparte na DBN i dostrajanie hiperparametrów oparte na HSGO. Szczegóły dotyczące każdego modułu omówiono w poniższych sekcjach.

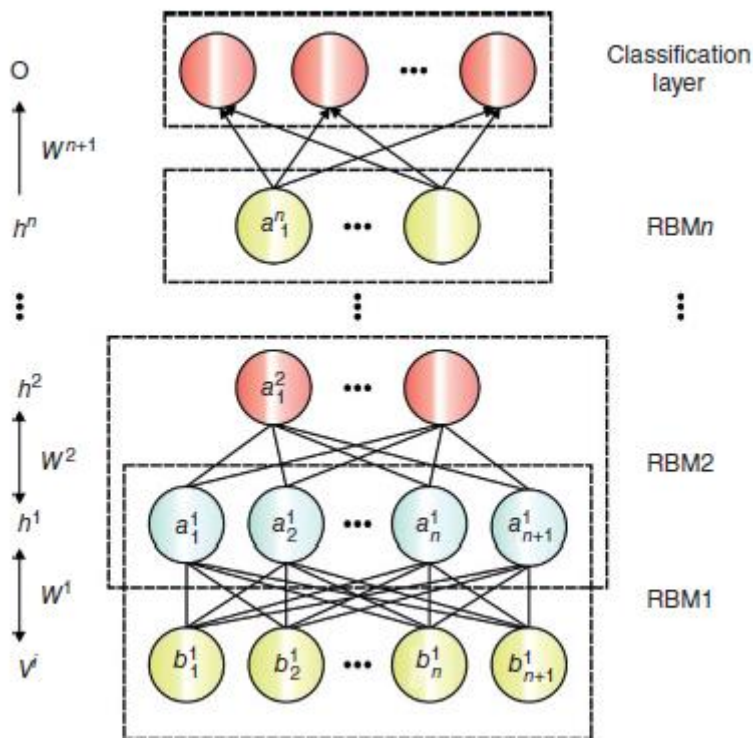
Normalizacja wyniku Z

Wynik Z to ustandaryzowane i znormalizowane podejście oparte na konwencji, które oznacza wielkość odchylenia standardowego (SD), surowego punktu danych występującego powyżej/poniżej średniej populacji. Idealnie leży pomiędzy -3 i $+3$. Normalizuje zbiór danych do wyżej wymienionej skali w celu konwersji każdej informacji o różnych skalach na skalę domyślną. W celu normalizacji informacji przy użyciu wskaźnika Z można go odjąć od średniej populacji w surowym punkcie danych i oddzielić SD, które zapewnia wynik idealnie różny od -3 do $+3$, zatem odzwierciedlające kilka SD znajduje się o punkt powyżej lub poniżej średniej obliczonej zgodnie z równaniem. (3.1), gdzie x implikuje wartość konkretnego przypadku, μ oznacza średnią, a σ oznacza SD.

$$z\text{-score} = \frac{(x - \mu)}{\sigma} \quad (3.1)$$

Model przewidywania oparty na DBN

Po wstępnym przetworzeniu danych wejściowych model DBN jest wykorzystywany do prognozowania danych o przepływie ruchu. DBN to element składowy DNN, który obejmuje odrębne warstwy, takie jak perceptron wielowarstwowy (MLP) i ograniczona maszyna Boltzmann (RBM). RBM składa się z jednostki ukrytej i jednostki widocznej, które są ze sobą połączone zgodnie z połączeniem ważonym. MLP przyjęto jako sieć neuronową ze sprzężeniem zwrotnym (FFNN), która zawiera warstwy ukryte, wejściowe i wyjściowe. Załóżmy, że istnieją dwa RBM, takie jak RBM1 i RBM2, a dane wejściowe do RBM1 to wektor cech uzyskany z dużych zbiorów danych. Rysunek przedstawia strukturę techniki DBN.



Warstwy ukrytą i wejściową neuronu wejściowego RBM1 podano w następujący sposób:

$$\varepsilon^1 = \{\varepsilon_1^1, \varepsilon_2^1, \varepsilon_3^1, \dots, \varepsilon_i^1, \dots, \varepsilon_m^1\}; \quad 1 \leq i \leq m \quad (3.2)$$

$$\beta^1 = \{\beta_1^1, \beta_2^1, \dots, \beta_c^1, \dots, \beta_f^1\}; \quad 1 \leq c \leq f \quad (3.3)$$

Gdzie ε^1 oznacza i-tą warstwę wejściową istniejącą w RBM1 oraz ilość warstw wejściowych RBM1 była równoważna wektorowi cech wymiarowych. Istnieje m neuronu z warstwy wejściowej RBM1 do realizacji klasyfikacji. Rozważ całkowitą liczbę ukrytych warstw w RBM1 be f i c-tą warstwę ukrytą z RBM2 be β^1 . Odchylenie ukrytych i widocznych warstw RBM1 podano w następujący sposób:

$$A^1 = \{A_1^1, A_2^1, A_3^1, \dots, A_i^1, \dots, A_m^1\} \quad (3.4)$$

$$O^1 = \{O_1^1, O_2^1, \dots, O_c^1, \dots, O_f^1\} \quad (3.5)$$

Odchylenie warstwy wejściowej i ukrytej RBM1 jest równoważne ogólnej liczbie neuronów w wagach, a warstwy RBM1 pokazano poniżej:

$$a^1 = \{a_{ic}^1\}; \quad 1 \leq i \leq m; \quad 1 \leq c \leq f \quad (3.6)$$

Gdzie a_{ic}^1 charakteryzuje wagę RBM1 i może to być waga pomiędzy i-tą warstwą wejściową i c-tą warstwą ukrytą RBM1. Odtąd wypadkową RBM1 można przedstawić w następujący sposób:

$$\beta_c^1 = \text{fun} \left[O_c^1 + \sum_i \tau_i^1 a_{ic}^1 \right] \quad (3.7)$$

Tutaj zabawa charakteryzuje funkcję aktywacji z RBM1 i τ_i^1 oznacza wektor cech jako. Wynik RBM1 można sformułować w następujący sposób:

$$\beta^1 = \{\beta_c^1\}; \quad 1 \leq c \leq f \quad (3.8)$$

Wynik z RBM1 jest podawany jako wkład do RBM2, a wynik RBM2 jest oceniany za pomocą poprzedniego równania. Wynik RBM2 jest pokazany jako G^2 , który jest dostarczany jako wejście do warstwy MLP. Neuron wejściowy w MLP jest formułowany przez:

$$\lambda = \{\lambda_1, \lambda_2, \dots, \lambda_e, \dots, \lambda_f\}; \quad 1 \leq c \leq f \quad (3.9)$$

Podczas gdy f pokazuje ogólne warstwy wejściowe z MLP. Ukryty neuron MLP jest pokazany jako:

$$E = \{E_1, E_2, \dots, E_x, \dots, E_y\}; \quad 1 \leq x \leq y \quad (3.10)$$

W równaniu y pokazuje całkowite ukryte warstwy MLP. Stronniczość ukrytego neuronu jest formułowana przez,

$$B = \{B_1, B_2, \dots, B_w, \dots, B_z\}; \quad 1 \leq w \leq z \quad (3.11)$$

Gdzie z oznacza neuron wyjściowy w warstwie MLP. Ciężary wśród neuronów wejściowych i ukrytych pokazano jako,

$$a^{\text{mlp}} = \{a_{cx}^{\text{mlp}}\}; \quad 1 \leq c \leq f; \quad 1 \leq x \leq y \quad (3.12)$$

Niech u_{cx}^{mlp} będzie wektorami wag pomiędzy c-tą warstwą wejściową i x-tą warstwą ukrytą. Wynik ukrytych neuronów w MLP zależy od wag i obciążenia,

$$O^{\text{hid}} = \left[\sum_{c=1}^f a_{cx}^{\text{mlp}} \times F_c \right] a_x \quad (3.13)$$

Stąd a_x pokazuje stroniczość neuronów wyjściowych. Wektory wag pomiędzy warstwami wyjściowymi i ukrytymi są pokazane w następujący sposób:

$$a' = \{a'_{xw}\}; 1 \leq x \leq y; \quad 1 \leq w \leq z \quad (3.14)$$

W tym przypadku wyniki MLP można ocenić za pomocą:

$$B_w = \sum_{x=1}^y a'_{xw} \times O^{hid} \quad (3.15)$$

Gdzie a'_{xw} pokazuje wagi między warstwami wyjściowymi i ukrytymi w MLP, a O^{hid} oznacza wyjście ukrytego neuronu.

Model optymalizacji hiperparametrów oparty na HSGO

Aby optymalnie dostroić hiperparametry (takie jak szybkość uczenia się, liczba epok i wielkość partii) modelu DBN, stosuje się algorytm HSGO. HSGO to nowa technika wielohybrydowa (MH), która inspirowana jest prawem Henry'ego. W porównaniu z technikami populacyjnymi, HSGO zaczyna się od pierwotnej wartości grupy N gazów lub roztworów (S) i zależy to od przestrzeni poszukiwań i wyraża się jako:

$$X_i = Lb + rand * (Ub - Lb), \quad rand \in [0, 1] \quad (3.16)$$

gdzie Lb i Ub oznaczają odpowiednio dolną i górną wartość z przestrzeni poszukiwań. Zbiór gazów X jest skupiony w równoważnej liczbie grup N_g , a wszystkie grupy oznaczają rodzaj gazu. Wszystkie grupy mają wartość zbliżoną do stałej Henry'ego, którą wyznacza się wzorem:

$$H_j = l \times r_1, \quad j = 1, 2, \dots, N_g, \quad l = 5E - 2 \quad (3.17)$$

gdzie r_1 oznacza dowolną liczbę, a l oznacza stałą. Kolejnym krokiem jest wyznaczenie gazu optymalnego we wszystkich grupach. Następnie definiowane są całe grupy skupień gazów optymalnych. Następnie współczynnik Henry'ego (H_j) do grupy j został podniesiony do postaci:

$$H_j(t+1) = H_j(t) \times \exp\left(-C_j \times \left(\frac{1}{T(t)} - \frac{1}{T^0}\right)\right), \quad T(t) = \exp\left(-\frac{t}{iter}\right) \quad (3.18)$$

gdzie T^0 i $iter$ oznaczają odpowiednio temperaturę, stałą wartość (ustaloną na 298,15) i maksymalną liczbę iteracji. HSGO poprawia rozpuszczalność (S_{ij}) X_i , ($i = 1, 2, \dots, N$) w każdej grupie jako:

$$S_{ij}(t) = K \times H_j(t+1) \times P_{ij}(t) \quad (3.19)$$

gdzie K odnosi się do stałej, a $P_{ij}(t)$ oznacza ciśnienie cząstkowe i -tego gazu z j -tego klastra j , i można to wykazać jako:

$$P_{ij}(t) = l_2 \times r_1, \quad j = 1, 2, \dots, N_g, \quad l_2 = 100 \quad (3.20)$$

Gaz X_i , który trafił do j -tego klastra, został ulepszony w oparciu o równanie. (3.21).

$$X_{ij}(t+1) = X_{ij}(t) + F_g \times r \times \eta \times (X_{ib}(t) - X_{ij}(t)) + F_g \times r \times \alpha \times (S_{ij}(t) \times X_{ib}(t) - X_{ij}(t)) \quad (3.21)$$

gdzie $\eta = \beta \times \exp\left(-\frac{F_b(t) + e}{F_{ij}(t) + e}\right)$ które określiły zdolność i-tych gazów do oddziaływania z innymi gazami z j-tej grupy. F_{ij} oznacza wartość sprawności X_j w j-tej grupie, a F_b oznacza optymalną wartość sprawności. F_g odnosi się do wartości pedafu, która modyfikuje kierunek gazów. $\alpha = 1$ oznacza kontrolę innych gazów na X_j z grupy j. Aby ominąć punkty lokalne, HGSO ulepsza gorsze gazy N_w , jak w równaniu. (3.22).

$$G_{ij} = G_{ij}^{\min} + r \times (G_{ij}^{\max} - G_{ij}^{\min}), \quad i = 1, 2, \dots, N_w \quad (3.22)$$

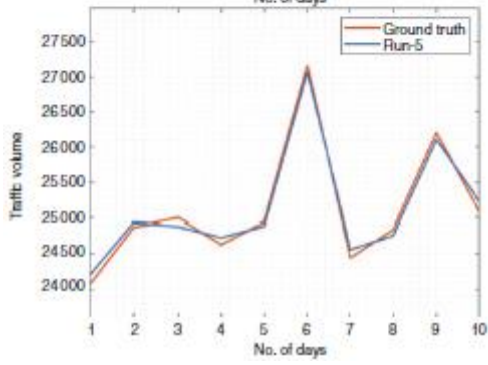
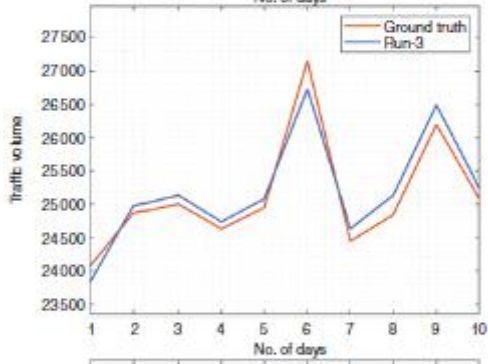
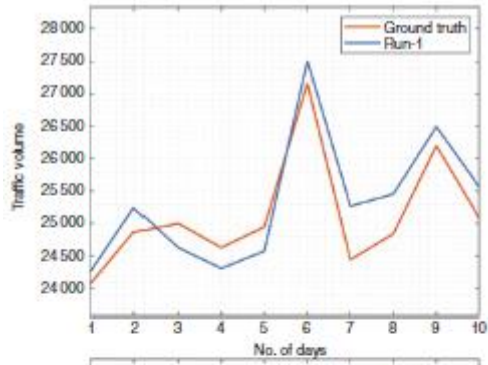
$$N_w = N \times r \times (c_2 - c_1) + c_1, \quad c_1 = 0.1, \quad \text{and} \quad c_2 = 0.2 \quad (3.23)$$

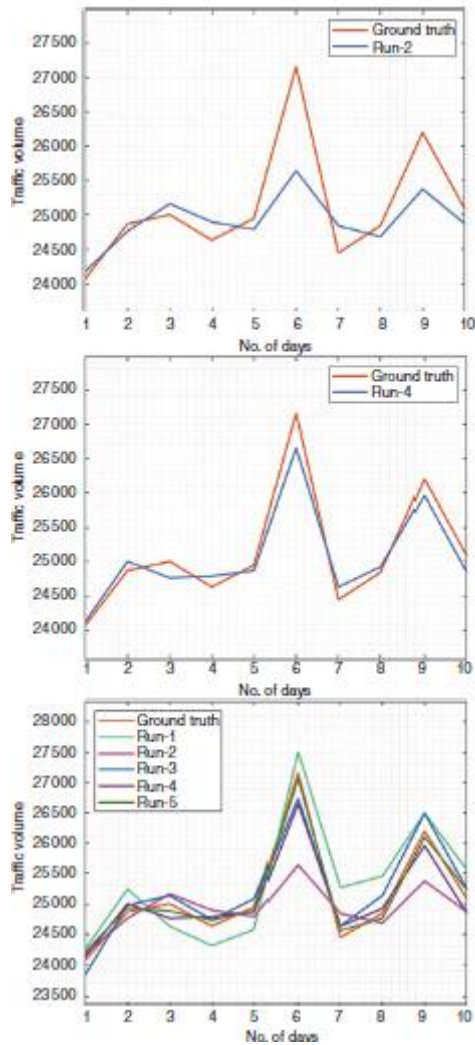
G_{ij} definiuje gaz X_i z j-tej grupy, który trafia do gazu gorszego.

Walidacja eksperymentalna

Walidację wydajności modelu HGSODL-TFF przeprowadzamy na podstawie danych o ruchu zebranych przez nas w sieciach kołowych obsługujących 6G. Wyniki prognozowania są sprawdzane w ramach różnych przebiegów testowych i czasów trwania. Tabela i rysunek przedstawiają rzeczywiste i przewidywane natężenie ruchu modelu HGSODL-TFF w pięciu różnych przebiegach.

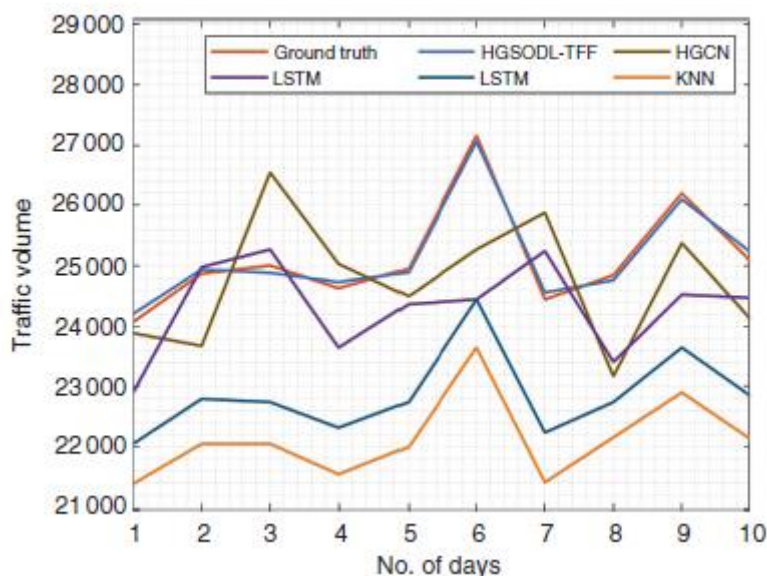
No. of days	Ground truth	Run-1	Run-2	Run-3	Run-4	Run-5
1	24 071	24 257	24 178	23 832	24 124	24 206
2	24 869	25 242	24 763	24 976	25 003	24 937
3	25 003	24 630	25 162	25 136	24 763	24 882
4	24 630	24 311	24 896	24 736	24 790	24 729
5	24 949	24 577	24 790	25 082	24 869	24 890
6	27 158	27 504	25 641	26 732	26 652	27 064
7	24 444	25 269	24 843	24 630	24 630	24 558
8	24 843	25 455	24 683	25 136	24 923	24 761
9	26 200	26 493	25 375	26 493	25 960	26 102
10	25 082	25 561	24 869	25 242	24 843	25 229





Wyniki wykazały, że model HGSODL-TFF zapewnił maksymalną wydajność przewidywania we wszystkich dniach i seriach. Na przykład pierwszego dnia model HGSODL-TFF osiągnął przewidywane wartości odpowiednio 24 257, 24 178, 23 832, 24 124 i 24 206 w seriach 1–5. Podobnie w dniu 4 podejście HGSODL-TFF osiągnęło przewidywane wartości odpowiednio 24 311, 24 896, 24 736, 24 790 i 24 729 w seriach 1–5. Podobnie w dniu 6 system HGSODL-TFF osiągnął odpowiednio przewidywane wartości 27 504, 25 641, 26 732, 26 652 i 27 064 w seriach 1–5. Oprócz tego w ósmym dniu system HGSODL-TFF osiągnął przewidywane wartości odpowiednio 25 455, 24 683, 25 136, 24 923 i 24 761 w seriach 1–5. Wreszcie w 10. dniu podejście HGSODL-TFF osiągnęło przewidywane wartości odpowiednio 25 561, 24 869, 25 242, 24 843 i 25 229 w seriach 1–5. Porównanie wyników prognozowania natężenia ruchu modelu HGSODL-TFF z modelami istniejącymi przedstawiono w tabeli i rysunku .

No. of days	Ground truth	HGSODL-TFF	HGCN	LSTM	GBRT	KNN
1	24 071	24 206	23 885	22 900	22 049	21 384
2	24 869	24 937	23 672	24 976	22 794	22 049
3	25 003	24 882	26 546	25 269	22 741	22 049
4	24 630	24 729	25 029	23 645	22 315	21 543
5	24 949	24 890	24 497	24 364	22 741	21 996
6	27 158	27 064	25 269	24 444	24 444	23 645
7	24 444	24 558	25 881	25 242	22 235	21 410
8	24 843	24 761	23 167	23 406	22 741	22 155
9	26 200	26 102	25 375	24 524	23 645	22 900
10	25 082	25 229	24 124	24 470	22 847	22 129

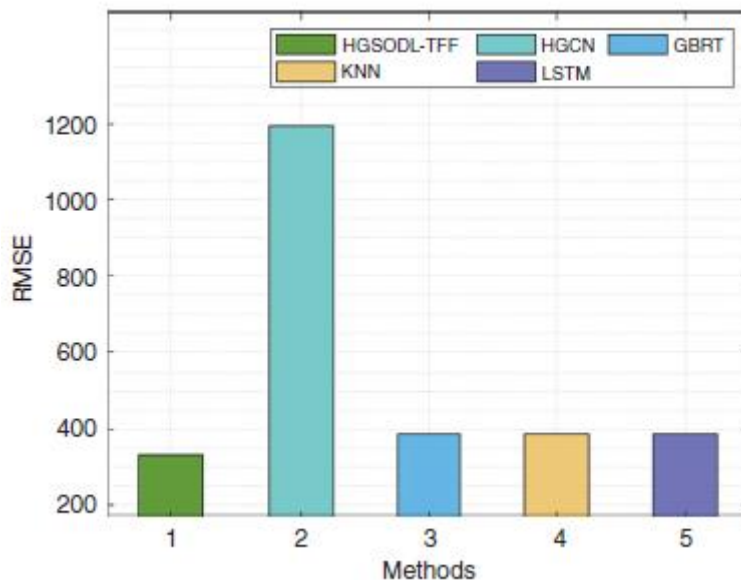


Wyniki wykazały, że model HGSODL-TFF przewyższa istniejące techniki w różnych dniach. Na przykład pierwszego dnia model HGSODL-TFF skutecznie przewidział natężenie ruchu na poziomie 24 206, podczas gdy sieci konwolucyjne z grafami hiperbolicznymi (HGCN), długa pamięć krótkoterminowa (LSTM), drzewa regresji ze wzmocnieniem gradientowym (GBRT) i Modele algorytmu najbliższych sąsiadów (KNN) wykazały natężenie ruchu odpowiednio 23 885, 22 900, 22 049 i 21 384. Jednocześnie w dniu 4 metoda HGSODL-TFF skutecznie przewidziała natężenie ruchu na poziomie 24 729, podczas gdy techniki HGCN, LSTM, GBRT i KNN osiągnęły natężenie ruchu odpowiednio na poziomie 25 029, 23 645, 22 315 i 21 543 . Ostatecznie w szóstym dniu metoda HGSODL-TFF skutecznie przewidziała natężenie ruchu na poziomie 24 558, podczas gdy algorytmy HGCN, LSTM, GBRT i KNN osiągnęły natężenie ruchu odpowiednio na poziomie 25 881, 25 242, 22 235 i 21 410 . Tymczasem w dniu 8 system HGSODL-TFF skutecznie przewidział natężenie ruchu na 24 761, podczas gdy techniki HGCN, LSTM, GBRT i KNN uzyskały natężenie ruchu na 23 167, 23 406, 22 741 i 22 155, odpowiednio. Wreszcie w dniu 10 model HGSODL-TFF skutecznie przewidział natężenie ruchu na poziomie 25 229, podczas gdy metodologie HGCN, LSTM, GBRT i KNN osiągnęły natężenie ruchu odpowiednio na poziomie 24


124, 24 470, 22 847 i 22 129 . Aby wykazać udoskonalenie modelu HGSODL-TFF, w Tabeli przedstawiono badanie porównawcze z najnowszymi metodami.

Methods	RMSE	MAE	MAPE (%)
HGSODL-TFF	332.47	257.54	2.41
HGCN	1194.72	956.93	3.68
GBRT	387.86	346.01	5.47
KNN	387.86	346.01	5.47
LSTM	387.86	346.01	5.47

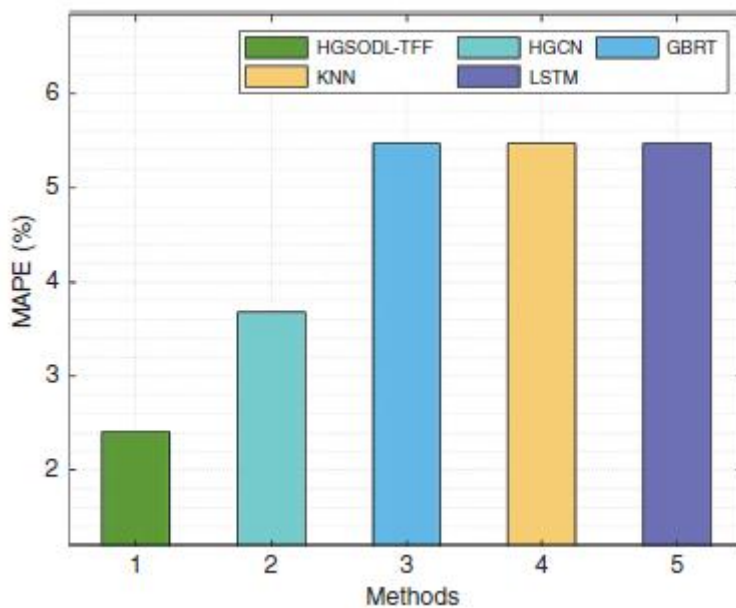
Porównawcze badanie błędu średniokwadratowego (RMSE) modelu HGSODL-TFF z istniejącymi metodami przedstawiono na rysunku



Wyniki pokazują, że model HGCN zaowocował słabą wydajnością przy maksymalnym RMSE wynoszącym 1194,72. Modele KNN i LSTM zapewniają lepszą wydajność niż GBRT i osiągają RMSE na poziomie 387,86. Jednakże model HGSODL-TFF osiągnął lepsze wyniki przy najmniejszym RMSE wynoszącym 332,47. Szczegółowe badanie MAE systemu HGSODL-TFF istniejącymi metodami przedstawiono na rysunku.



Wyniki to pokazały technika HGCN spowodowała słabą wydajność z maksymalnym MAE wynoszącym 956,93. Oprócz tego modele GBRT, KNN i LSTM osiągnęły nieco lepszą wydajność przy identycznym MAE wynoszącym 346,01. Jednakże technika HGSODL-TFF osiągnęła maksymalny wynik przy najmniejszym MAE wynoszącym 257,54. Porównanie badania MAPE modelu HGSODL-TFF z istniejącymi metodami przedstawiono na rysunku .



Wyniki wykazały, że model HGCN zaowocował gorszą wydajnością przy maksymalnym MAPE wynoszącym 3,68%. KNN i LSTM zapewniają lepszą wydajność niż GBRT z MAPE wynoszącym 5,47%. Wreszcie metodologia HGSODL-TFF osiągnęła doskonałe wyniki przy najmniejszym MAPE wynoszącym 2,41%. Powyższe wyniki wskazały na wyższość modelu HGSODL-TFF nad wynikami prognozowania nad innymi metodami.

Wniosek

W tym badaniu opracowano nową technikę HGSODL-TFF do przewidywania przepływu ruchu w sieci VANET wspomaganą przez sieć 6G. Prezentowany model HGSODL-TFF obejmuje trzy różne procesy,

takie jak przetwarzanie wstępne, przewidywanie oparte na DBN i dostrajanie hiperparametrów oparte na HSGO. Algorytm HSGO można zastosować do optymalnej modyfikacji hiperparametrów (takich jak szybkość uczenia się, liczba epok i wielkość partii) modelu DBN, a tym samym poprawy wydajności prognozowania. Walidację eksperymentalną modelu HGSODL-TFF przeprowadza się na danych testowych, a wyniki sprawdza się pod kilkoma względami. Wyniki symulacji wykazały poprawę modelu HGSODL-TFF w porównaniu z innymi najnowszymi podejściami. W przyszłości hybrydowe modele DL będą mogły zostać wykorzystane do zwiększenia wyników predykcyjnych modelu HGSODL-TFF.