

Dobór zestawu maszyn do robót ziemnych w aspekcie minimalizacji emisyjności CO₂

Magdalena Rogalska

¹*Katedra Inżynierii Procesów Budowlanych, Wydział Budownictwa i Architektury,
Politechnika Lubelska, e-mail: m.rogalska@o2.pl*

Streszczenie: Celem opracowania algorytmu obliczeń jest umożliwienie doboru zestawu maszyn do robót ziemnych w aspekcie minimalizacji emisyjności CO₂. W pracy prognozowano wydajność koparek oraz emisyjność CO₂ zestawów maszyn. Wykorzystano metody prognozowania regresji wielorakiej i sieci neuronowych. Przeprowadzono analizę autokorelacji i autokorelacji cząstkowej reszt oraz analizę wrażliwości. Obliczono błędy MAPE prognoz. Na podstawie otrzymanych modeli prognostycznych wykonano przykład obliczeniowy doboru maszyn w aspekcie emisyjności dwutlenku węgla.

Słowa kluczowe: zrównoważony rozwój, wydajność koparek, emisja CO₂, regresja wieloraka, sieci neuronowe.

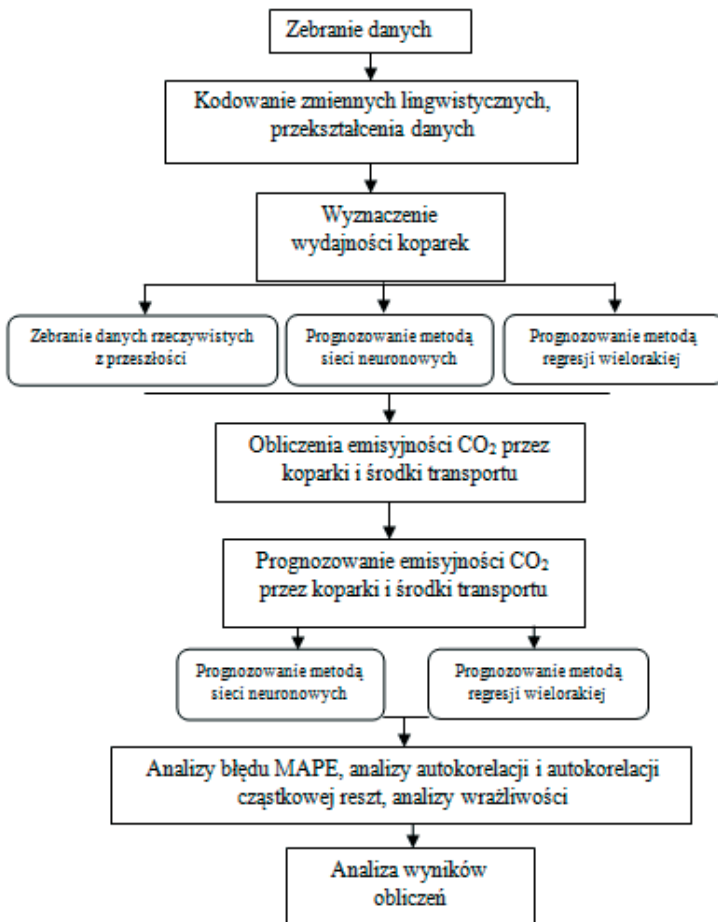
1. Wstęp

Zapotrzebowanie budynków i budowli na energię należy rozpatrywać w całym cyklu życia obiektu. Energia całkowita wznoszenia obiektów [5] składa się z energii materiałowej (niezbędnej do wyprodukowania i utylizacji materiałów budowlanych), energii procesowej (energii niezbędnej do realizacji procesów budowlanych) i energii transportowej. Należy dążyć do minimalizacji zużycia energii na każdym etapie życia budynku: podczas budowy, eksploatacji i utylizacji obiektu. Celem pracy jest opracowanie metodologii obliczeń i oceny emisyjności CO₂ podczas wykonywania procesów budowlanych. Analizę przeprowadzono na przykładzie wykonywania wykopów z wykorzystaniem koparek gąsiennicowych i samochodów samowyładowczych. Opisana metodologia umożliwi wybór zestawu maszyn do realizacji procesu w aspekcie minimalizacji emisji dwutlenku węgla. Zastosowano metody prognozowania: regresji wielorakiej [1,2,3] i sieci neuronowych. Obliczenia wykonano przy zastosowaniu programu STATISTICA. Metodologię obliczeń przedstawiono na rysunku 1 [4].


2. Dane

Dane dotyczące koparek pozyskano z Katalogu Norm Robocizny 2-01. Analizowano koparki gąsiennicowe przedsiębiorne, podsięberne, zgarniarkowe i chwytakowe. Zebrano dane mające hipotetyczny wpływ na wydajność koparek: pojemność łyżki, rodzaj narzędzia roboczego i kategorię gruntu. Wydajność koparek jest kluczową daną do obliczeń. Wiadomo, że zależy ona od umiejętności operatora, podobnie jak ilość zużytego paliwa. Ilość zużywanego paliwa oszacowano na podstawie danych z firmy Skanska S.A. Przy stosowaniu modeli prognostycznych

uzyskuje się wyniki najbardziej zbliżone do rzeczywistych wówczas gdy wykorzystuje się dane pomierzone w przeszłości. Często metodą wykorzystywaną do określania wydajności koparek jest interpolacja danych z KNR. Nie jest to metoda prawidłowa, ponieważ nie ma prostej zależności liniowej lub też wielomianowej pomiędzy pojemnością łyżki koparki a jej wydajnością rys.2. Na rysunku 2 widać wyraźnie bardzo duży rozrzut pomierzonych wartości. Zatem metoda interpolacji nie jest wystarczająco dokładna.



Rys. 1. Schemat blokowy obliczania emisyjności CO₂ przez koparki i środki transportu.



Zmienna	Opis zmiennej	Uwagi
v11	Zużycie paliwa samochód samowładowczy od 5 do 10t [dm ³]/100km	Jw.
v12	Emisja CO ₂ koparka [kg]	Ze spalenia 1 dm ³ oleju napędowego powstaje 1,49 kg CO ₂
v13	Emisja CO ₂ samochód samowładowczy do 5t [kg]	jw.
v14	Emisja CO ₂ samochód samowładowczy od 5 do 10t [kg]	jw.
v15	Log(v3)	Logarytm naturalny wartości pojemności łyżki
v16	Log(v4)	Logarytm naturalny kodu koparki odpowiednio: 4,615121 dla 101, 4,62497281 dla 102, 4,63472899 dla 103 i 4,6443909 dla 104
v17	Log(v5)	Logarytm naturalny kodu kategorii gruntu, wartości jak wyżej
v18	v15 ²	
v19	MR1(v6; v3,v15,v16,v17)	Prognoza wydajności koparek określona metodą regresji wielorakiej. Oznaczenia: MR Multiple Regression model 1, zmienna zależna v6, zmienne niezależne – predyktory równania v3,v15,v16,v17,v18
v20	RMR1	Reszty modelu regresji wielorakiej MR1
v21	SN1(v6;v3,v4,v5,v15,v16,v17,v18) MLP 13-4-1	Prognoza wydajności koparek określona metodą sieci neuronowych, model 1, sieć typu perceptron wielowarstwowy o 13 warstwach wejściowych, 4 ukrytych i jednej wyjściowej.
v22	RSN1	Reszty modelu SN1
v23	MR2(v1; v15,v17,v18)	Prognoza emisji CO ₂ przez koparkę i samochód samowładowczy do 5t określona metodą regresji wielorakiej. Oznaczenia: MR Multiple Regression model 2, zmienna zależna v1, zmienne niezależne – predyktory równania v15,v17,v18
v24	RMR2	Reszty modelu regresji wielorakiej MR2
v25	SN2(v1; v3,v4,v5,v6,v15,v16,v17,v18) MLP 13-9-1	Prognoza emisji CO ₂ przez koparkę i samochód samowładowczy do 5t określona metodą sieci neuronowych, model 1, sieć typu perceptron wielowarstwowy o 13 warstwach wejściowych, 9 ukrytych i jednej wyjściowej.
v26	RSN2	Reszty modelu SN2
v23	MR3(v2; v15,v17,v18)	Prognoza emisji CO ₂ przez koparkę i samochód samowładowczy od 5t do 10t określona metodą regresji wielorakiej. Oznaczenia: MR Multiple Regression model 3, zmienna zależna v2, zmienne niezależne – predyktory równania v15,v17,v18
v24	RMR3	Reszty modelu regresji wielorakiej MR3
v25	SN3(v2; v3,v4,v5,v6,v15,v16,v17,v18) MLP 13-4-1	Prognoza emisji CO ₂ przez koparkę i samochód samowładowczy od 5t do 10t określona metodą sieci neuronowych, model 3, sieć typu perceptron wielowarstwowy o 13 warstwach wejściowych, 4 ukrytych i jednej wyjściowej.
v26	RSN3	Reszty modelu SN3

3. Prognozowanie wydajności koparek

W pracy zaproponowano prognozowanie wydajności koparek dwoma metodami: regresji wielorakiej i przy wykorzystaniu sieci neuronowych..


3.1. Metoda regresji wielorakiej MR1(v6;v3,v15,v16,v17)

Do obliczeń zastosowano metodę regresji wielorakiej wstecznej. Zmienną zależną jest v6 wydajność koparek. Jako zmienne niezależne przyjęto v3,v15,v16,v17,v18 (tabela 1). W toku obliczeń uzyskano 4 predyktory v3,v15,v16,v17. Otrzymano równanie regresyjne postaci (1), podsumowanie regresji zmiennej zależnej v6 zamieszczono w tabeli 2, wykres zależności zmiennej zależnej v6 i prognozy przedstawiono na rysunku 3. Celem sprawdzenia prawidłowości modelu wykonano wykresy autokorelacji i autokorelacji reszt, rysunek 4. Stwierdzono występowanie autokorelacji reszt przy 12 opóźnieniu szeregu, nie jest to zatem rozwiązanie idealne ale dopuszczalne. Można przyjąć, że szereg resztowy modelu jest białym szumem. Obliczono błąd MAPE %, wynosi on dla analizowanego modelu 11,57297 %. Wynik można uznać za dostatecznie dobry.


Tabela 2. Podsumowanie regresji modelu MR1(v6;v3,v15,v16,v17)

N=52		Podsumowanie regresji zmiennej zależnej: Wydajność koparki [m-g] R= ,97565245 R ² = ,95189771 Skorygowane R ² = ,94780390 F(4,47)=232,52 p<0,0000 Błąd std. estymacji: ,55345				
	b*	Bł. std. z b*	b	Bł. std. z b	t(47)	p
W. wolny			-500,122	48,43319	-10,3260	0,000000
Pojemność łyżki [m3]	0,66869	0,097791	2,458	0,35939	6,8380	0,000000
Log(v3)	-1,46250	0,097466	-5,111	0,34061	-15,0052	0,000000
Log(v4)	0,24812	0,033944	53,561	7,32751	7,3096	0,000000
Log(v5)	0,23942	0,032064	54,636	7,31712	7,4669	0,000000

$$v6 = -500,122 + 2,458 * v3 - 5,111 * v15 + 53,561 * v16 + 54,636 * v17 \quad (1)$$



Rys. 3. Wykres zależności zmiennej zależnej v6 i prognozy otrzymanej z modelu MR1(v6;v3,v15,v16,v17).



Rys. 4. Funkcja autokorelacji i autokorelacji cząstkowej reszt modelu MR1(v6;v3,v15,v16,v17).


3.2. Metoda sieci neuronowych SN1 MLP 13-4-1

Do obliczeń zastosowano metodę sieci neuronowych. Zmienną zależną jest v6 wydajność koparek, tak jak poprzednio. Jako zmienne niezależne przyjęto v3,v4,v5,v15,v16,v17,v18 (w metodzie sieci neuronowych można wprowadzać bezpośrednio do obliczeń również dane lingwistyczne). Wprowadzając zmienne niezależne w liczbie 7, z których dwie są zmiennymi lingwistycznymi (po 4 rodzaje), otrzymujemy w omawianej metodzie $(7-2)+2*4=13$ zmiennych niezależnych. W wyniku przeprowadzonych obliczeń uzyskano model sieci neuronowej o parametrach zestawionych w tabeli 3.


Tabela 3. Parametry sieci SN1(v6; v3,v4,v5,v15,v16,v17,v18) MLP 13-4-1.

Podsumowanie najlepszej sieci					
Id sieci	Nazwa sieci	Jakość (uczenie)	Jakość (testowanie)	Jakość (walidacja)	Błąd (uczenie)
1	MLP 13-4-1	0,999305	0,999387	0,983714	0,004506
Podsumowanie najlepszej sieci					
Id sieci	Nazwa sieci	Jakość (uczenie)	Jakość (testowanie)	Jakość (walidacja)	Błąd (uczenie)
1	MLP 13-4-1	0,999305	0,999387	0,983714	0,004506

Wykres zależności zmiennej zależnej v_6 i prognozy przedstawiono na rysunku 5. Celem sprawdzenia prawidłowości modelu wykonano wykresy autokorelacji i autokorelacji reszt, rysunek 6. Można przyjąć, że szereg resztowy modelu jest białym szumem. Obliczony błąd MAPE wynosi 2,414899 % - wynik bardzo dobry.



Rys. 5. Wykres zależności zmiennej zależnej v_6 i prognozy otrzymanej z modelu $SN1(v_6; v_3, v_4, v_5, v_{15}, v_{16}, v_{17}, v_{18})$ MLP 13-4-1



Rys. 6. Funkcja autokorelacji i autokorelacji cząstkowej reszt modelu $SN1(v_6; v_3, v_4, v_5, v_{15}, v_{16}, v_{17}, v_{18})$ MLP 13-4-1

Wniosek: Model prognozowania wydajności koparki SN1(v6; v3,v4,v5,v15, v16,v17,v18) MLP 13-4-1 może być przyjęty do dalszych obliczeń, spełnia on wszystkie wymagania. Model MR1(v6;v3,v15,v16,v17) jest dopuszczalny do stosowania lecz nie polecany ze względu na dokładność.

4. Prognozowanie emisji CO₂ podczas pracy koparki i samochodu samowyładowczego do 5t, transport urobku 100 m³ na odległość 1 km

W pracy zaproponowano prognozowanie emisji CO₂ podczas pracy koparki i samochodu samowyładowczego do 5t (transport urobku 100 m³ na odległość 1 m), dwoma metodami : regresji wielorakiej i przy wykorzystaniu sieci neuronowych. Metoda regresji generuje wzór obliczeniowy łatwy do interpretacji i zastosowania. Druga z proponowanych metod jest bardzo dokładna, lecz wymaga arkusza kalkulacyjnego z danymi zamieszczonymi w tabeli 1.

4.1. Metoda regresji wielorakiej MR2(v1;v15,v17,v18)

Do obliczeń zastosowano metodę regresji wielorakiej wstecznej. Zmienną zależną jest v1 zgodnie z opisem tab.1. Jako zmienne niezależne przyjęto v3,v6,v15,v16,v17,v18. W toku obliczeń uzyskano 3 predyktory v15,v17,v18. Otrzymano równanie regresyjne postaci (2). Celem sprawdzenia prawidłowości modelu wykonano wykresy autokorelacji i autokorelacji reszt. Stwierdzono występowanie autokorelacji reszt przy 1 opóźnieniu szeregu, oraz występowanie autokorelacji cząstkowej reszt przy 1, 3 i 4 opóźnieniu. Szereg resztowy modelu nie jest białym szumem. Obliczono błąd MAPE %, wynosi on dla analizowanego modelu 0,970509 %.

$$v1 = -784,025 + 16,141 \cdot v15 - 179,703 \cdot v17 + 7,183 \cdot v18 \quad (2)$$

Wniosek: model MR2(v1;v15,v17,v18) nie może być przyjęty jako model regresji wielorakiej, ponieważ nie spełnia podstawowego warunku równania regresyjnego – szereg resztowy modelu nie jest białym szumem (występują autokorelacje i autokorelacje cząstkowe reszt). Pomimo bardzo wysokiej wartości skorygowanego współczynnika regresji $R^2 = 0,99396121$ oraz bardzo niskiego błędu MAPE = 0,970509 %, model nie może być stosowany. Zależności pomiędzy zmienną zależną a predyktorami nie są liniowe.


4.2. Metoda sieci neuronowych model SN2 MLP 14-9-1

Do obliczeń zastosowano metodę sieci neuronowych. Zmienną zależną jest v1 zgodnie z opisem w tabeli 1. Jako zmienne zależne przyjęto v3,v4,v5,v6,v15,v16,v17,v18. W wyniku przeprowadzonych obliczeń uzyskano model sieci neuronowej o parametrach zestawionych w tabeli 4.


Tabela 4. Parametry sieci SN2(v1; v3,v4,v5,v6,v15,v16,v17,v18) MLP 14-9-1.


Podsumowanie najlepszej sieci					
Id sieci	Nazwa sieci	Jakość (uczenie)	Jakość (testowanie)	Jakość (walidacja)	Błąd (uczenie)
1	MLP 14-9-1	1,000000	0,999978	0,999935	0,000017
Podsumowanie najlepszej sieci					
Błąd (testowanie)	Błąd (walidacja)	Algorytm uczenia	Funkcja błędu	Aktywacja (ukryte)	Aktywacja (wyjściowe)
0,000548	0,009926	BFGS 170	SOS	Tanh	Liniowa

Wykres zależności zmiennej zależnej $v1$ i prognozy przedstawiono na rysunku 7. Celem sprawdzenia prawidłowości modelu wykonano wykresy autokorelacji i autokorelacji reszt, rysunek 8. Można przyjąć, że szereg resztowy modelu jest białym szumem (autokorelacje przy 11 opóźnieniu są statystycznie nieistotne). Obliczony błąd MAPE wynosi 0,039633 % - wynik znakomity.



Rys. 7. Wykres zależności zmiennej zależnej $v1$ i prognozy otrzymanej z modelu SN2(v1; v3,v4,v5,v6,v15,v16,v17,v18) MLP 14-9-1, bardzo dobre dopasowanie.





Rys. 8. Funkcja autokorelacji i autokorelacji cząstkowej reszt modelu SN2(v1; v3,v4,v5,v6,v15,v16,v17,v18) MLP 14-9-1.

Przeprowadzono analizę wrażliwości modelu, wyniki zamieszczono w tabeli 5. Największy wpływ w modelu na emisję CO₂ ma pojemność łyżki koparki. Wpływ wszystkich predyktorów jest istotny. Nie przewiduje się rezygnacji z któregoś z nich i opracowywania nowego modelu predykcyjnego.

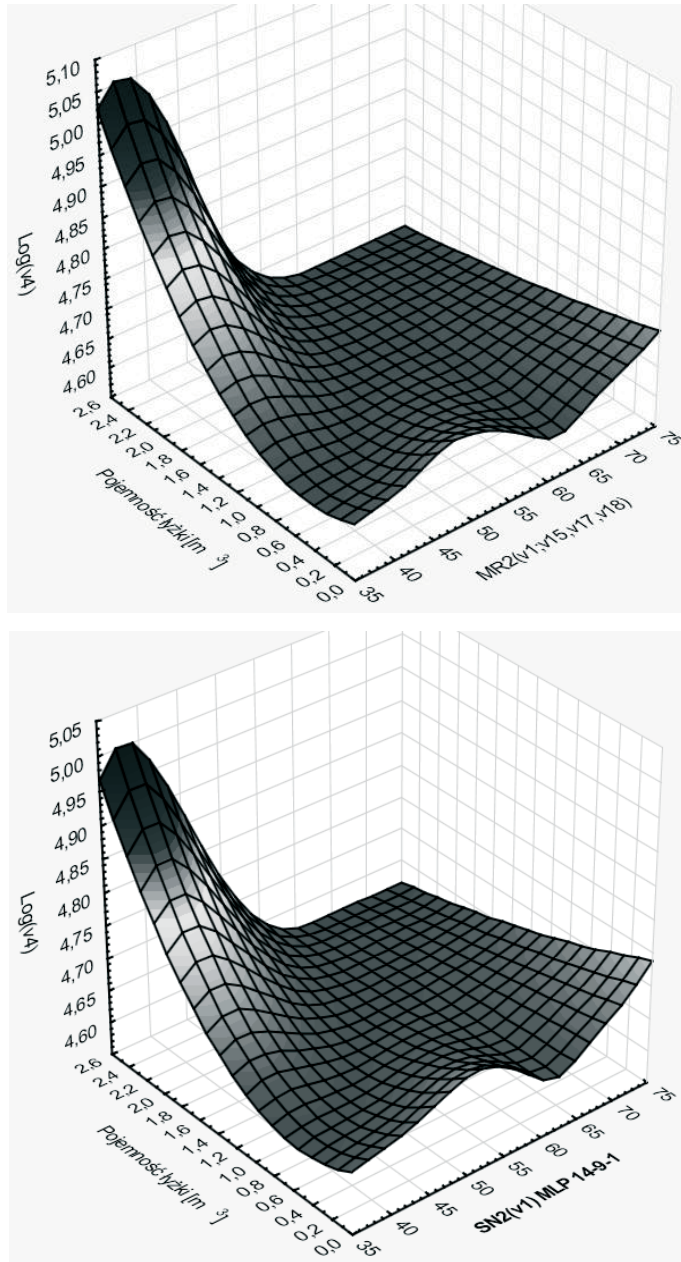
Tabela 5. Analiza wrażliwości modelu SN2.

Analiza wrażliwości Próby: Uczenie, Test, Walidacja MLP 14-9-1							
Pojemność łyżki [m ³]	Rodzaj koparki	Kategoria gruntu	Log(v3)	Log(v3) ²	Log(v4)	Log(v5)	Wydajność koparki
13265,04	3103,926	2822,291	2249,36	571,1774	444,176	59,2803	47,73744


4.3. Analiza wyników prognozowania emisji CO₂ podczas pracy koparki i samochodu samowładowczego do 5t, transport urobku 100 m³ na odległość 1 km metodami regresji wielorakiej i sieci neuronowych

Istnieje możliwość prognozowania emisji CO₂ powstającego w wyniku pracy koparek i samochodów wyładowczych metodą sieci neuronowych. Pomimo pozornie bardzo dobrych wyników prognozy otrzymanej metodą regresji wielorakiej, metoda ta nie może być stosowana. Celem zobrazowania wyników obu metod wykonano wykresy trójwymiarowe (rysunek 9) zależności pojemności łyżek koparek, logarytmu naturalnego kodu koparek oraz prognoz metodą regresji wielorakiej MR2(v1;v15,v17,v18) i sieci neuronowej SN2(v1; v3,v4,v5,v6,v15,v16,v17,v18) MLP 14-9-1. Wykresy wykonane metodą wygładzania najmniejszych kwadratów ważonych odległościami. Jak widać na wykresach modelowane powierzchnie są bardzo podobne. Model regresji wielorakiej w tym przypadku jest zgodny z modelem sieci neuronowych. Sytuacja się diametralnie zmienia gdy porównywane są wykresy trójwymiarowe zależności pojemności łyżek koparek, logarytmu naturalnego kodu kategorii gruntu oraz prognoz metodą regresji wielorakiej MR2(v1;v15,v17,v18) i sieci neuronowej SN2(v1; v3,v4,v5,v6,v15,v16,v17,v18) MLP 14-9-1 (rysu-

nek 10). Model regresji wielorakiej w sposób istotny niweluje minima i maksima lokalne. Właśnie z tego powodu wykresy autokorelacji i autokorelacji cząstkowej były nieprawidłowe, pomimo doskonałego skorygowanego współczynnika regresji równego 0,99396121 oraz bardzo niskiego błędu MAPE = 0,970509 %.



Rys. 9. Wykresy trójwymiarowe zależności pojemności łyżek koparek, logarytmu naturalnego kodu koparek oraz prognoz metodą regresji wielorakiej $\text{MR2}(v_1;v_{15},v_{17},v_{18})$ i sieci neuronowej $\text{SN2}(v_1; v_3,v_4,v_5,v_6,v_{15},v_{16},v_{17},v_{18})$ MLP 14-9-1, wykresy wykonane metodą wygładzania najmniejszych kwadratów ważonych odległościami.



Rys. 10. Wykresy trójwymiarowe zależności pojemności łyżek koparek, logarytmu naturalnego kodu kategorii gruntu oraz prognoz metodą regresji wielorakiej MR2(v1;v15,v17,v18) i sieci neuronowej SN2(v1; v3,v4,v5,v6,v15,v16,v17,v18) MLP 14-9-1, wykresy wykonane metodą wygładzania najmniejszych kwadratów ważonych odległościami.


5. Prognozowanie emisji CO₂ podczas pracy koparki i samochodu samowyładowczego do 10t, transport urobku 100 m³ na odległość 1 km

Zaproponowano prognozowanie emisji CO₂ podczas pracy koparki i samochodu samowyładowczego do 10t (transport urobku 100 m³ na odległość 1km), dwoma metodami: regresji wielorakiej i przy wykorzystaniu sieci neuronowych.

5.1. Metoda regresji wielorakiej MR3(v2;v15,v17,v18)

Do obliczeń zastosowano metodę regresji wielorakiej wstecznej. Zmienną zależną jest v2 zgodnie z opisem tabeli 1. Jako zmienne niezależne przyjęto v3,v6,v15,v16,v17,v18. W toku obliczeń uzyskano 3 predyktory v15,v17,v18. Otrzymano równanie regresyjne postaci (3), Celem sprawdzenia prawidłowości modelu wykonano wykresy autokorelacji i autokorelacji reszt, rysunek 11. Stwierdzono występowanie autokorelacji reszt i autokorelacji reszt przy pierwszym opóźnieniu szeregu. Szereg resztowy modelu nie jest białym szumem. Obliczono błąd MAPE %, wynosi on dla analizowanego modelu 1,061148 %.

$$v2 = -590,659 + 16,149 \cdot v15 - 137,252 \cdot v17 + 7,184 \cdot v18 \quad (3)$$



Rys. 11. Funkcja autokorelacji i autokorelacji częściowej reszt modelu MR3(v2;v15,v17,v18).

Wniosek: Model MR3(v2;v15,v17,v18) nie może być przyjęty jako model regresji wielorakiej, ponieważ nie spełnia podstawowego warunku równania regresyjnego – szereg resztowy modelu nie jest białym szumem (występują autokorelacje i autokorelacje częściowe reszt). Pomimo bardzo wysokiej wartości skorygowanego współczynnika regresji $R^2 = 0,99367929$ oraz bardzo niskiego błęd MAPE = 1,061148 %, model nie może być stosowany. Zależności pomiędzy zmienną zależną a predyktorami nie są liniowe.


5.2. Metoda sieci neuronowych model SN3 MLP 14-4-1

Do obliczeń zastosowano metodę sieci neuronowych. Zmienną zależną jest v2 zgodnie z opisem w tabeli 1. Jako zmienne zależne przyjęto v3,v4,v5,v6,v15,v16,v17,v18. W wyniku przeprowadzonych obliczeń uzyskano model sieci neuronowej o parametrach zestawionych w tabeli 6.


Tabela 6. Parametry sieci SN3(v2; v3,v4,v5,v6,v15,v16,v17,v18) MLP 14-4-1

Podsumowanie najlepszej sieci					
Id sieci	Nazwa sieci	Jakość (uczenie)	Jakość (testowanie)	Jakość (walidacja)	Błąd (uczenie)
1	MLP 14-4-1	0,999913	0,999887	0,999312	0,007195
Podsumowanie najlepszej sieci					
Błąd (testowanie)	Błąd (walidacja)	Algorytm uczenia	Funkcja błędu	Aktywacja (ukryte)	Aktywacja (wyjściowe)
0,006265	0,103071	BFGS 124	SOS	Wykładnicza	Liniowa

Wykres zależności zmiennej zależnej v2 i prognozy przedstawiono na rysunku 12. Celem sprawdzenia prawidłowości modelu wykonano wykresy autokorelacji i autokorelacji reszt, rysunek 13. Można przyjąć, że szereg resztowy modelu jest białym szumem. Obliczony błąd MAPE wynosi 0,320443 % - wynik znakomity.



Rys. 12. Wykres zależności zmiennej zależnej v2 i prognozy otrzymanej z modelu. SN3(v2; v3,v4,v5,v6,v15,v16,v17,v18) MLP 14-4-1, bardzo dobre dopasowanie.



Rys. 13. Funkcja autokorelacji i autokorelacji cząstkowej reszt modelu SN3(v2; v3,v4,v5,v6,v15,v16,v17,v18) MLP 14-4-1

Przeprowadzono analizę wrażliwości modelu, wyniki zamieszczono w tabeli 7. Największy wpływ w modelu na emisję CO₂ ma pojemność łyżki koparki (zmienna w postaci logarytmu naturalnego z nadanego kodu). Wpływ wszystkich predyktorów jest istotny. Nie przewiduje się rezygnacji z któregoś z nich i opracowywania nowego modelu predykcyjnego.

Tabela 7. Analiza wrażliwości modelu SN3

Analiza wrażliwości Próby: Uczenie, Test, Walidacja MLP 14-4-1							
Log(v3)	Kategoria gruntu	Pojemność łyżki [m ³]	Rodzaj koparki	Log(v3)^2	Wydajność koparki	Log(v5)	Log(v4)
3819,808	243,7286	146,3180	137,655	135,5025	121,314	53,7949	20,07061

Wniosek: Model prognozowania SN3(v2;v3,v4,v5,v6,v15,v16,v17,v18) MLP 14-4-1 emisji CO₂ podczas pracy koparki i samochodu samowładowczego do 10t (transport urobku 100 m³ na odległość 1km) może być przyjęty do dalszych obliczeń, spełnia on wszystkie wymagania.

6. Przykład obliczeniowy

Wykop, wielkości 5000 m³, należy wykonać w gruncie kategorii trzeciej. Należy ustalić, która z wytypowanych koparek A czy B, będzie powodowała mniejszą emisję CO₂ i przy jakiej pojemności skrzyni samochodu samowładawczego emisja dwutlenku węgla będzie mniejsza. Transport urobku przewidziano na odległość 1 km. Dane koparek podano poniżej:

Koparka A – Komatsu HB215 LC Hybrid, pojemność łyżki 1,36 m³, podsiębierna.

Koparka B – Komatsu PC 210 LC/NLC-8, pojemność łyżki 1,68 m³, przedsiębiorna.

Rozwiązanie:

Wyznaczenie wydajności koparek A i B przy wykorzystaniu modelu prognostycznego sieci neuronowych SN1(v6; v3,v4,v5,v15,v16,v17,v18) MLP 13-4-1.

Tabela 8. Wyznaczenie wydajności koparek A i B – sieć neuronowa.

Nazwa koparki	Wydajność koparki [m-g]	Pojemność łyżki [m ³]	Log(v3)	Log(v4)	Log(v5)	Log(v3) ²
Komatsu HB215 LC Hybrid	2,770706	1,360000	0,30748	4,62500	4,63500	0,094544
Komatsu PC 210 LC/NLC-8	2,114217	1,680000	0,51879	4,61500	4,63500	0,269143

Nazwa koparki	Kategoria gruntu	Rodzaj łyżki koparki
Komatsu HB215 LC Hybrid	trzecia	podsiębierna
Komatsu PC 210 LC/NLC-8	trzecia	przedsiębierna

Wyznaczenie emisji CO₂ podczas pracy koparki i samochodu samowładawczego do 5t, transport urobku 100 m³ na odległość 1 km przy wykorzystaniu modelu prognostycznego sieci neuronowych SN2(v1; v3,v4,v5,v6,v15,v16,v17,v18) MLP 14-9-1

Tabela 9. Wyznaczenie emisji CO₂ podczas pracy koparki i samochodu samowładawczego do 5t.

Nazwa koparki	Emisja CO ₂ koparka i samochód 5t [kg]	Pojemność łyżki [m ³]	Wydajność koparki [m-g]	Log(v3)	Log(v4)
Komatsu HB215 LC Hybrid	54,21870	1,360000	2,770706	0,30748	4,62500
Komatsu PC 210 LC/NLC-8	58,64021	1,680000	2,114217	0,51879	4,61500

Nazwa koparki	Log(v5)	Log(v3) ²	Rodzaj koparki	Kategoria gruntu
Komatsu HB215 LC Hybrid	4,635000	0,094544	podsiębierna	trzecia
Komatsu PC 210 LC/NLC-8	4,635000	0,269143	przedsiębierna	trzecia

Wyznaczenie emisji CO₂ podczas pracy koparki i samochodu samowładawczego do 10t, transport urobku 100 m³ na odległość 1 km przy wykorzystaniu modelu prognostycznego sieci neuronowych SN3(v2; v3,v4,v5,v6,v15,v16,v17,v18) MLP 14-4-1

Tabela 10. Wyznaczenie emisji CO₂ podczas pracy koparki i samochodu samowyładowczego do 10t.

Nazwa koparki	Emisja CO ₂ koparka i samochód 10t [kg]	Pojemność łyżki [m ³]	Wydajność koparki [m-g]	Log(v3)	Log(v4)
Komatsu HB215 LC Hybrid	50,91911	1,360000	2,770706	0,30748	4,625000
Komatsu PC 210 LC/NLC-8	53,75219	1,680000	2,114217	0,51879	4,625000

Nazwa koparki	Log(v5)	Log(v3)^2	Rodzaj koparki	Kategoria gruntu
Komatsu HB215 LC Hybrid	4,635000	0,094544	podsiębierna	trzecia
Komatsu PC 210 LC/NLC-8	4,635000	0,269143	przedsiębierna	trzecia

Wyznaczenie emisji CO₂ podczas pracy koparki i samochodu samowyładowczego – wykop 1450 m³.

Tabela 11. Wyznaczenie emisji CO₂ podczas pracy zespołu maszyn.

Koparka	Samochód samowyładowczy	Emisja CO ₂ [kg] 100 m ³	Emisja CO ₂ [kg] 5000 m ³	Ranking
Komatsu HB215 LC Hybrid	do 5t	54,21870	2710,935	3
	od 5t do 10t	50,91911	2545,955	1
Komatsu PC 210 LC/NLC-8	do 5t	58,64021	2932,011	4
	od 5t do 10t	53,75219	2687,610	2

Odpowiedź: Najmniejszą emisyjność CO₂ (w określonych zadaniem warunkach) wykazuje zestaw maszyn koparka Komatsu HB215 LC Hybrid i samochód samowyładowczy o pojemności skrzyni od 5 do 10 t.

7. Podsumowanie

Istnieje możliwość prognozowania emisji dwutlenku węgla zestawu maszyn do robót ziemnych przy zastosowaniu metody sieci neuronowych. Na podstawie prognozy w sposób analityczny można dobrać odpowiedni zespół maszyn tak by spełniał kryteria zrównoważonego rozwoju. Z przeprowadzonych analiz wynika, że kryterium minimalizacji emisji dwutlenku węgla jest wprost proporcjonalne do pojemności łyżki koparki i ładowności środka transportowego. Zatem im koparka ma większą pojemność łyżki a samochód samowyładowczy większą nośność, tym z punktu widzenia minimalizacji CO₂, rozwiązanie jest lepsze. Nie zaleca się określania wydajności koparek poprzez liniową interpolację.

Literatura

- [1] Cieślak M. *Prognozowanie gospodarcze : metody i zastosowanie*. Warszawa, Wydaw. Naukowe PWN, 2001.
- [2] Kot S., Jakubowski J., Sokołowski A. *Statystyka*. Difin, Warszawa 2007.
- [3] Martyniak Z. *Wstęp do inwentyki*. Wydawnictwo Uczelniane, Kraków, 1997 s.32.

- [4] Rogalska M., Hejducki Z. *Prognozowanie emisyjności CO₂ koparek gąsiennicowych i samochodów samowładawczych metodami regresji wielorakiej i sieci neuronowych*. Archiwum Instytutu Inżynierii Lądowej 13 (2012) 293-298.
- [5] Rogalska M., Hejducki Z. *Analiza doboru materiałów budowlanych w aspekcie zrównoważonego rozwoju*. Przegląd Budowlany 2/2007

Selection of a set of earthmoving equipment in the aspect minimizing the emission of CO₂

Magdalena Rogalska

*Department of Production Engineering and Construction Management,
Faculty of Civil Engineering and Architecture, Lublin University of Technology ,
e-mail: m.rogalska@o2.pl*

Abstract: The aim of the calculation is to allow the selection of a set of earthmoving machinery in terms of minimizing the emission of CO₂. The capacity of excavators and CO₂ emission of set of machines was predicted. The forecasting methods: multiple regression and neural networks were used. The analysis of autocorrelation and partial autocorrelation residuals and sensitivity analysis were performed. The MAPE errors of forecasts were calculated. The calculation example in terms of selection of machines emission of carbon dioxide on the basis of forecasting models was performed.

Keywords: sustainable development, the performance of excavators, CO₂ emissions, multiple regression, neural networks.