

Dr inż. Janusz Rusek

AGH University of Science and Technology
Al. A. Mickiewicza 30, 30-059 Kraków, Poland
E-mail: rusek@agh.edu.pl

Application of Support Vector Machine in the analysis of the technical state of development in the LGOM mining area

Zastosowanie metody Support Vector Machine w analizie stanu technicznego zabudowy terenu górniczego LGOM

Słowa kluczowe: *Support Vector Machine, wpływy górnicze, odporność budynków, zużycie techniczne, stan techniczny*

Key words: *Support Vector Machine, influence of mining, structure resistance, technical wear, technical condition*

Streszczenie: W pracy przedstawiono wyniki analizy zużycia technicznego budynków zlokalizowanych w zasięgu wpływów eksploatacji górniczej na terenie *Legnicko-Głogowskiego Okręgu Miedziowego (LGOM)*. W badaniach zastosowano pokrewną sieciom neuronowym metodę wektorów podpierających (*Support Vector Machine*) w podejściu regresyjnym ε -SVR (*Support Vector Regression*). Celem badań było uzyskanie oceny wpływu zmiennych opisujących zabezpieczenia konstrukcyjne i remonty na przebieg modelowanego zjawiska. Podstawą do analiz był utworzony model zużycia technicznego budynków w postaci sieci ε -SVR. Oprócz zmiennych określających poziom zabezpieczeń konstrukcyjnych i remontów, w modelu uwzględniono zmienne opisujące: deformacje terenu pochodzenia górniczego, intensywność wstrząsów oraz wiek budynków. Dobór parametrów modelu przeprowadzono z wykorzystaniem, jako bezgradientowej metody optymalizacyjnej, algorytmu genetycznego. Bazując na utworzonym modelu ε -SVR przeprowadzono dwurodzajową analizę wrażliwości. Oceny wpływu zabezpieczeń konstrukcyjnych dokonano badając zmienność wektora gradientu modelowanej hiperpowierzchni. Natomiast analiza wpływu remontów na przebieg modelowanego procesu została przeprowadzona na bazie komparacji wyników symulacji modelu ε -SVR.

Wyniki badań potwierdziły przydatność przyjętej metodyki badań oraz pozwoliły na sformułowanie istotnych wniosków dotyczących wpływu analizowanych czynników na zużycie techniczne tradycyjnej zabudowy *LGOM*.

Abstract: The paper presents the results of the analysis of technical wear of buildings located within impact of mining plant in the *Legnica - Głogów Copper District (LGOM)*. The study used method related to neural networks, support vector (*Support Vector Machine*) in regression approach ε -SVR (*Support Vector Regression*). The aim of the study was to assess the impact of variables describing the structural protection and renovations on the course modeled phenomenon. The basis for the analysis was created model of technical wear of buildings in the form of a network ε -SVR. In addition to the variables determining the level of structural protection and renovations in the model included variables describing: terrain deformation, mining intensity tremors and the age of the buildings. The choice of model parameters were performed using, as gradientlessness optimization method, genetic algorithm. Based on the established model ε -SVR two types of sensitivity analysis were applied. Assessing the impact of the structural protections have been studying by the analysis of variability of the gradient

vector for the modeled hypersurface. The analysis of the impact of renovations on the course modeled process was carried out based on the comparator simulation results of ε -SVR model. The results confirmed the usefulness of the methodology of research and allowed to draw important conclusions on the impact of analyzed factors on the technical wear traditional buildings *LGOM*.

1. Wstęp

Odporność obiektów budowlanych na wpływy eksploatacji górniczej uwarunkowana jest ich stanem technicznym, którego miarą jest zużycie techniczne. Wyniki prowadzonych w ostatnich latach badań [6,7] potwierdziły istotny wpływ na zużycie techniczne budynków oddziaływań eksploatacji górniczej zarówno w formie deformacji terenu, jak i wstrząsów górniczych. Wykazały również znaczenie zabezpieczeń konstrukcyjnych oraz bieżących remontów. Relacje te pozostawały jednak niejawnie w kontekście matematycznej formy funkcyjnej. Uzasadniło to wykorzystanie w dalszych pracach bardziej złożonych metod analitycznych uwzględniających wielowymiarowość oraz nieliniowość modelowanego procesu. Model taki powinien pozwolić na efektywniejszą ocenę stanu technicznego budynków oraz analizę wpływu poszczególnych zmiennych wchodzących w opis modelowanego zjawiska. Biorąc to pod uwagę, w przedstawionych w artykule badaniach zastosowano model przebiegu zużycia technicznego jako sieć *SVM* (*Support Vector Machine*) w ujęciu regresyjnym ε -SVR (*Support Vector Regression*).

Metoda *SVM* [8,25], jak i jej ujęcie regresyjne ε -SVR [4,21], stanowią podgrupę metod zaliczanych do działu *Uczenia Maszynowego* (*Machine Learning*). Struktura tych systemów jest bardzo zbliżona do sztucznych sieci neuronowych *ANN* (*Artificial Neural Network*) [17]. Wybór metody *SVM* dla przeprowadzenia prezentowanych w pracy badań był podyktowany tym, iż:

- w metodzie ε -SVR nie występuje konieczność zadawania startowej funkcji odwzorowania, co pozwala na stworzenie modelu dla wielowymiarowego procesu, w którym relacje między zmiennymi mają charakter nieliniowy [6,7] lecz bez sprecyzowanej ściśle postaci funkcyjnej,
- w odróżnieniu do sztucznych sieci neuronowych, procedura budowy sieci ε -SVR pozwala na optymalną, w sensie własności generalizacyjnych, rozbudowę swojej struktury która odbywa się w trakcie procesu kalibracji wartości parametrów C , ε i γ . Parametry te, opisane w rozdziale 3 niniejszej pracy, są zawarte w pierwotnym sformułowaniu funkcji celu dla metody ε -SVR [21,25],
- finalna postać matematyczna sieci ε -SVR pozwala na relatywnie proste wyznaczenie wartości pochodnych cząstkowych, które z kolei są podstawą analizy wrażliwości modelu względem wytypowanych zmiennych wejściowych typu ciągłego.

Prezentowany w pracy model zużycia technicznego został utworzony na drodze optymalnego doboru parametrów C , ε i γ z wykorzystaniem pakietu *LIBSVM* [6] oraz *algorytmu genetycznego GA* [19]. W celu wyodrębnienia wpływu zmiennej opisującej poziom zabezpieczeń konstrukcyjnych (w_{ZAB}), przeprowadzono analizę wrażliwości modelu polegającą na badaniu przebiegu składowej gradientu dla tak zdefiniowanego czynnika. Z kolei, aby ustalić wpływ skategoryzowanej zmiennej w_{REM} , opisującej zakres prowadzonych prac remontowych porównano wartości predykcji modelu uzyskane na drodze jego symulacji.

2. Opis bazy danych o budynkach

Podstawę do analiz stanowiła baza danych, obejmująca grupę 930 murowanych budynków mieszkalnych zlokalizowanych w zasięgu wpływów górniczych kopalń *KGHM "Polska Miedź" S.A.* Baza danych o budynkach została utworzona w ramach inwentaryzacji stanu technicznego. Na etapie szczegółowych oględzin każdy budynek zewidencjonowano przy pomocy 93 zmiennych. Zmienne te opisują lokalizację obiektu, dane geometryczne, rodzaj zabudowy, dane na temat elementów konstrukcyjnych i wykończeniowych, wiek budynków, zużycie techniczne ustalone *metodą średniej ważonej* [23], zakres prowadzonych prac remontowych, poziom zabezpieczeń konstrukcyjnych przeciw wpływom eksploatacji górniczej oraz aktualne, na czas przeprowadzenia inwentaryzacji, wpływy od eksploatacji górniczej w postaci wskaźników deformacji oraz charakterystyk wstrząsów górniczych.

Badana zabudowa jest poddawana oddziaływaniom górniczym od ponad 40 lat. Początkowo wynikały one z kształtowania się niecki obniżeniowej nad wyrobiskami górniczymi oraz wielkopowierzchniowej niecki związanej z odwodnieniem górotworu [23]. Od 30 lat na obszarze *LGOM* występują również wstrząsy górnicze [24].

W *LGOM* budynki wznoszone po 1970 roku są zabezpieczane na etapie budowy przed wpływami deformacji terenu spowodowanymi eksploatacją górniczą. Budynki starsze są również systematycznie poddawane zabiegom profilaktycznym (kotwienie, żelbetowe opaski, itp.). Od końca lat 80. XX wieku w nowowznoszonych obiektach wprowadza się również zabezpieczenia konstrukcyjne przed wpływami parasejsmicznymi.

Do oceny stopnia zużycia badanych budynków stosowano tzw. *metodę średniej ważonej* (np. [23]). Polega ona na indywidualnej ocenie stopnia zużycia poszczególnych elementów, a następnie - przez nadanie im odpowiednich wag - ustaleniu średnioważonego stopnia zużycia całego budynku.

Aby sprecyzować i opisać ilościowo czynniki wpływające na stan techniczny zabudowy zdefiniowano dodatkowo dwa wskaźniki: w_{REM} oraz w_{ZAB} .

Wskaźnik zabezpieczeń w_{ZAB} zdefiniowano za pomocą tzw. *kategorii odporności obiektu (KO)*, która stanowi charakterystykę konstrukcyjną budynku oraz *kategorii zagrożenia terenu ze strony oddziaływań górniczych (KT)*.

Kategorie terenu górniczego (KT) opisują intensywność ciągłych deformacji powierzchni, wyrażoną przez przypisanie charakteryzujących ją wartości nachyleń (T), krzywizn (R) i poziomych odkształceń terenu (ε) do określonych przedziałów (od 0 do V). Z kolei przez *kategorię odporności obiektu (KO)* rozumiana jest odporność budynku na poziome odkształcenia i krzywiznę terenu odpowiadające przedziałom wartości tych wskaźników w *kategoriach terenu górniczego (KT)* - (od 0 do 4) [np. 9]. Obiekt uznaje się za odporny na wpływy górnicze gdy kategoria jego odporności KO nie jest mniejsza od kategorii terenu górniczego KT . W praktyce przyjmuje się, że wykonanie w obiekcie zabezpieczeń ma na celu podniesienie kategorii odporności obiektu (KO) przynajmniej do poziomu występującej na danym terenie kategorii zagrożenia (KT).

W zależności od zakresu tych zabezpieczeń ustalano dla każdego budynku sumę punktów (p) wg empirycznej *metody punktowej oceny odporności budynków* [9], w zakresie od $p=0$ (*budynek zabezpieczony w poziomie fundamentów i wszystkich stropów*) do $p=15$ (*brak zabezpieczeń*). W efekcie, dla każdego budynku, zgodnie z zależnością (1), ustalono wartość wskaźnika w_{ZAB} .

$$w_{ZAB} = \begin{cases} \frac{(15-p)}{15} \cdot (|KT - KO|) + KO & \text{dla } KO < KT \\ \frac{(15-p)}{15} + KO & \text{dla } KO \geq KT \end{cases} \quad (1)$$

gdzie: KT – kategoria terenu górniczego, dla której wykonano dodatkowe zabezpieczenia profilaktyczne,
 KO – kategoria odporności budynku założona na etapie projektowania,
 p – liczba punktów z punktowej metody oceny odporności budynków dla danego zakresu zabezpieczeń.

Z kolei wskaźnik w_{REM} odzwierciedla zakres prowadzonej w budynkach gospodarki remontowej. Jest to zmienna skategoryzowana, opisywana wartościami: 1 – dla budynków nieremontowanych oraz 2 – dla budynków poddanych pracom remontowym w kompleksowym zakresie.

3. Metodyka badań

W tej części pracy przedstawiono:

- interludium matematyczne w zakresie podstawowych sformułowań dotyczących metody SVM w ujęciu regresyjnym,
- zastosowaną w pracy metodę kalibracji parametrów C , ε i γ warunkujących finalną postać struktury sieci SVM ,
- procedurę wyznaczania składowych gradientu w analizę wrażliwości.

3.1 Opis metody SVM w ujęciu regresyjnym (ε -SVR)

W podejściu regresyjnym w metodzie SVM zapis poszukiwanej funkcji aproksymującej ma postać [16]:

$$y(\mathbf{x}) = \mathbf{w}^T \varphi(\mathbf{x}) + b \quad (2)$$

gdzie: $\mathbf{x} \in R^n$ - jest wektorem danych wejściowych w przestrzenie n-wymiarowej,
 $\varphi(\cdot): R^n \rightarrow R^{n_h}$ - jest pewną transformacją przekształcającą surowe dane wejściowe do tzw. *przestrzeni cech systemu (feature space)*,
 \mathbf{w}^T - jest wektorem wag,
 b – wyraz wolny (bias)

Odwzorowanie $\varphi(\cdot): R^n \rightarrow R^{n_h}$ jest podawane w sposób niejawni i jest efektem zastosowania funkcji jądra określonego typu (np.[25]).

Podstawą do sformułowania problemu uczenia systemu SVM w ujęciu regresyjnym jest zdefiniowanie funkcji błędu minimalizowanej w procesie adaptacji. Dysponując pewnym zbiorem danych wzorcowych $\{\mathbf{x}_k, y_k\}_{k=1}^N$ funkcję kosztu dla pojedynczego wzorca zapisuje się jako (np.[25]):

$$L_\varepsilon(y_k, y(\mathbf{x}_k)) = \begin{cases} |y_k - y(\mathbf{x}_k)| - \varepsilon & \text{dla } |y_k - y(\mathbf{x}_k)| \geq \varepsilon \\ 0 & \text{dla } |y_k - y(\mathbf{x}_k)| \leq \varepsilon \end{cases} \quad (3)$$

Powyższe sformułowanie nosi nazwę ε – *niewrażliwej funkcji kosztu* (ε – *insensitive loss function* [10]). W wyniku stosowania powyższej funkcji, narzucającej pewien *margines tolerancji* ε , podejście regresyjne z wykorzystaniem SVM zwykło nazywać się ε -SVR (ε – *Support Vector Regression* (np.[21]).

Wprowadzenie takiej postaci funkcji błędu jest typowe dla tzw. *metod odpornych* na zakłócenia w danych bądź dane odstające [14]. Ponadto pozwala na późniejsze

sformułowanie problemu uczenia, jako zadania programowania kwadratowego [2], co jest jedną z głównych zalet metody ε -SVR.

Dysponując ustaloną funkcją błędu dla pojedynczego wzorca (3) zapisuje się funkcję celu, za minimalizacją której będzie podążać proces uczenia:

$$\min_{\mathbf{w}, b, \xi_k^*, \xi_k} J(\mathbf{w}, \xi_k^*, \xi_k) = \frac{1}{2} \mathbf{w}^T \mathbf{w} + C \sum_{k=1}^N (\xi_k^* + \xi_k), k = 1 \dots N \quad (4)$$

Przy nierównościowych ograniczeniach funkcyjnych:

$$y_k - \mathbf{w}^T \varphi(\mathbf{x}_k) - b \leq \varepsilon + \xi \quad (5)$$

$$\mathbf{w}^T \varphi(\mathbf{x}_k) + b - y_k \leq \varepsilon + \xi \quad (6)$$

$$\xi_k, \xi_k^* \geq 0 \quad (7)$$

Powyższy zapis jest tzw. pierwotnym problemem minimalizacji funkcji przy ograniczeniach nierównościowych (5), (6) i (7) (np.[2]).

Tak postawiony problem wprowadza kompromis pomiędzy generalizacją, a jakością dopasowania aproksymatora wyrażonego w postaci (2).

Człon $\sum_{k=1}^N (\xi_k^* + \xi_k)$ w zależności (4) łącznie z ograniczeniami (5), (6) i (7) odpowiada za minimalizację globalnej funkcji błędu dla wszystkich wzorców uczących:

$$L_\varepsilon^N = \frac{1}{N} \sum_{k=1}^N L_\varepsilon(y_k, y(\mathbf{x}_k)) \quad (8)$$

Wartości ξ_k^*, ξ_k są odchyłkami odwzorowania każdego wzorca poza zakładaną tolerancję błędu ε . W procesie uczenia dąży się do ich minimalizacji przy spełnieniu wszystkich ograniczeń funkcyjnych (5), (6) i (7). Z kolei człon $\frac{1}{2} \mathbf{w}^T \mathbf{w}$ odpowiada za poszerzenie tzw. marginesu separacji [16]. W podejściu regresyjnym, realizowanym w przestrzeni cech systemu, minimalizacja tego członu prowadzi do optymalnego ustalenia hiperpłaszczyzny aproksymatora w obrębie założonego pasma tolerancji błędu ε .

W sumie obydwie człony zależności (4) mają przeciwstawny charakter, a kompromis ustala się wprowadzając stałą regularyzacyjną C . Im większa jej wartość, tym dopasowanie systemu rośnie, natomiast spadają właściwości generalizacyjne i na odwrót.

Aby rozwiązać tak zdefiniowany problem minimalizacji, konstruuje się funkcje *Lagrange'a* (np.[2,14]). Tym samym otrzymuje się zapis zależności (4) rozszerzony o zbiór wszystkich ograniczeń (5), (6) i (7), sterowanych mnożnikami *Lagrange'a*:

$$\begin{aligned} L(\mathbf{w}, b, \xi_k, \xi_k^*, \alpha_k, \alpha_k^*, \mu_k, \mu_k^*) = & J(\mathbf{w}, \xi_k^*, \xi_k) - \sum_{k=1}^N \alpha_k (w^T \varphi(x_k) + b - y_k + \varepsilon + \xi_k) + \\ & - \sum_{k=1}^N \alpha_k^* (y_k - w^T \varphi(x_k) - b + \varepsilon + \xi_k^*) - \sum_{k=1}^N (\mu_k^* \xi_k^* + \mu_k \xi_k), k = 1 \dots N \end{aligned} \quad (9)$$

Następnie, stosując twierdzenie *Fermata* i wykorzystując warunki *Karusha-Kuhna-Tuckera* [25], otrzymuje się sformułowanie dualne programowania kwadratowego, wyrażone w dziedzinie mnożników *Lagrange'a* w postaci [14]:

$$\max_{\alpha_k, \alpha_k^*} Q(\alpha_k, \alpha_k^*) = \sum_{k=1}^N y_k (\alpha_k - \alpha_k^*) - \varepsilon \sum_{k=1}^N (\alpha_k + \alpha_k^*) - \sum_{k=1}^N \sum_{j=1}^N (\alpha_k - \alpha_k^*) (\alpha_j - \alpha_j^*) K(\mathbf{x}_k, \mathbf{x}_j) \quad (10)$$

Przy nierównościowych ograniczeniach funkcyjnych:

$$0 \leq \alpha_k^* \leq C \quad (11)$$

$$0 \leq \alpha_k \leq C \quad (12)$$

$$\sum_{k=1}^N (\alpha_k - \alpha_k^*) \geq 0 \quad (13)$$

Powyższe sformułowanie podlega dalej maksymalizacji względem mnożników Lagrange'a.

Pojawiający się w zależności (10) czynnik $K(\mathbf{x}_k, \mathbf{x}_j)$ jest jądrem systemu, który zadawany jest w sposób jawny i jest wynikiem złożenia niejawnych funkcji $\varphi(\cdot)$ [14]:

$$K(\mathbf{x}_k, \mathbf{x}_j) = \varphi(\mathbf{x}_k) \varphi(\mathbf{x}_j) \quad (14)$$

Postać jądra dobierana jest arbitralnie spośród wszystkich funkcji spełniających założenia twierdzenia *Mercera* [14].

W wyniku tak przeprowadzanej procedury uczenia, po ustaleniu wartości mnożników *Lagrange'a*, wyznacza się wektor wag z zależności:

$$\mathbf{w} = \sum_{k=1}^{N_{SV}} (\alpha_k - \alpha_k^*) \varphi(\mathbf{x}_k) \quad (15)$$

Co z kolei pozwala na zapis ostatecznej postaci aproksymatora:

$$y(\mathbf{x}) = \sum_{k=1}^{N_{SV}} (\alpha_k - \alpha_k^*) K(\mathbf{x}, \mathbf{x}_k) + b \quad (16)$$

3.2 Kalibracja parametrów C , ε i γ

Próbie wyznaczenia szukanych parametrów, dalej zwanych *hiperparametrami* podjęto w pracy [19], w której bazując na koncepcji *Meta-SVM* [10] wykorzystano dodatkowo miarę błędu *FPE (Final Prediction Error)* [19]. W dalszym toku badań zdecydowano jednak o podjęciu, zdaniem autora bardziej efektywnej, metody bazującej na koncepcji opisanej w [4]. Głównym etapem tej metody jest n -krotna walidacja skośna przeprowadzona na wstępnie przygotowanych zbiorach: treningowych i testujących. Dla każdej iteracji walidacji zakłada się pewien zakres rozpatrywanych parametrów C , ε i γ wyrażonych w skali logarytmicznej. Następnie, zgodnie z zaproponowanym algorytmem optymalizacyjnym *GS (Grid Search* np.[4]), przeprowadzana jest minimalizacja funkcji celu, przyjętej jako błąd *MSE (Mean Squared Error)* uśredniony ze wszystkich n zbiorów testowych wykorzystywanych w walidacji. W konsekwencji uzyskuje się optymalny zestaw szukanych hiperparametrów C , ε i γ . Algorytm *GS* jest bezgradientową metodą minimalizacji globalnej (np.[2]). Posiada on jednak pewną niedogodność, polegającą na konieczności podania zakresów dla

przeszukiwanego obszaru oraz zadaniu punktu startowego. Dlatego w pracy zamiast algorytmu *GS* zastosowano metodę optymalizacji bazującą na *algorytmie genetycznym GA* (*Genetic Algorithm*). Zastosowana metoda *GA* również jest algorytmem bezgradientowym, pozwalającym na wskazanie minimum globalnego np. [2, 15].

3.3. Analiza wrażliwości – badanie przebiegu składowych gradientu

Utworzony model *SVM*, podobnie jak w przypadku sztucznych sieci neuronowych *ANN* stanowi tzw. „czarną skrzynkę” i wykorzystywany jest przede wszystkim do estymacji wartości wyjściowych. W ostatnich latach, coraz częściej podejmuje się próby analiz wewnątrzstrukturalnych takich modeli [26]. Działania te mają na celu uszczegółowienie informacji o interakcjach pomiędzy zmiennymi wejściowymi, a zmienną wyjściową. Podstawowym i zarazem najprostszym zabiegiem, pozwalającym na ustalenie ilościowego wpływu poszczególnych zmiennych zależnych na wyjaśnienie pierwotnej zmienności zawartej w danych wyjściowych jest tzw. *eliminacja zmiennych*. Na kanwie takiego postępowania można dokonywać również selekcji najważniejszych zmiennych w modelu tzw. *selekcji cech* (*Feature Selection*) [3,13]. Innym podejściem, rzadziej podejmowanym, jest analiza przebiegu składowych gradientu względem każdej ze zmiennych wejściowych ujętych w modelu. Takie podejście, zastosowane w ramach przedstawianych w pracy badań, pozwala na jakościową i ilościową ocenę wpływu poszczególnych zmiennych na monotoniczność estymowanego procesu np. [5].

Metoda ta zastosowana została w pracy do badania wpływu ciągłej zmiennej jaką był wskaźnik w_{ZAB} . Aby przeprowadzić analizę wykorzystano analogie struktury modelu ε -*SVR* do *radialnych sieci neuronowych* (*Radial Basis Function Neural Networks* [16]). Tym samym przeprowadzono analizę wrażliwości zgodnie z procedurami proponowanymi w pracach: [5,18,22]. Wykorzystując fakt, że zapis aproksymatora ε -*SVR* można ująć w deterministyczną postać funkcyjną zgodnie z zależnością (16) dla dowolnej składowej wektora zmiennych wejściowych i w danym punkcie \mathbf{x}_p można wyznaczyć składową gradientu w postaci:

$$\frac{dy(\mathbf{x}_p)}{dx_{pi}} = 2\sigma \sum_{k=1}^{N_{SV}} (\alpha_k - \alpha_k^*) K(\mathbf{x}_p, \mathbf{x}_k) (x_{pi}, x_{ki}) \quad (17)$$

W zależności (13) czynnik $K(\mathbf{x}_k, \mathbf{x}_j)$ stanowi jądro systemu i przy wyborze radialnych funkcji bazowych przyjmuje postać:

$$K(\mathbf{x}_k, \mathbf{x}_j) = \exp\left(-\frac{(\mathbf{x}_k - \mathbf{x}_j)^2}{\gamma^2}\right)^{\sigma = \frac{1}{\gamma^2}} = \exp(-\sigma(\mathbf{x}_k - \mathbf{x}_j)^2) \quad (18)$$

4. Wyniki badań

4.1. Model aproksymujący przebieg zużycia technicznego budynków

Bazą do wnioskowania o wpływie wskaźników w_{REM} oraz w_{ZAB} był utworzony model predykcyjny w postaci struktury sieci ε -*SVR*. Ogólną charakterystykę modelu przedstawiono w tabeli 1 oraz rys. 1. Jako miary uszczegóławiające ocenę jakości uzyskanego modelu wykorzystano średnią z bezwzględnych wartości błędu pomiędzy odwzorowaniem modelu, a danymi rzeczywistymi *Ver* oraz tzw. *procent sukcesu* (*Success Ratio*) *SR* [%] w funkcji błędu względnego ep [%] [11]. Wyniki te przedstawiono w tabelach 2, 3 oraz 4.

W zestawie zmiennych wejściowych, oprócz badanych wskaźników znalazły się również: zmienna opisująca wiek budynku, wskaźnik odzwierciedlający wpływ deformacji ciągłych terenu górniczego $\varepsilon(+)$ oraz wskaźnik intensywności wstrząsów górniczych a_{sg} [24]. Szczegółowe analizy wstępne potwierdzające konieczność ujęcia tych zmiennych w modelu zostały szerzej omówione w pracach [6,7,23].

Wszystkie analizy zostały przeprowadzone w środowisku *Matlab* z wykorzystaniem pakietu *LIBSVM* [4] oraz *Genetic Algorithm Toolbox* [15].

Tabela 1. Podstawowe parametry podsumowujące model ε -SVR

Zbiór treningowy <i>Błąd MSE</i>	Zbiór testowy <i>Błąd MSE</i>	Liczba wektorów podpierających <i>nSV</i>	Parametr regularyzacyjny <i>C</i>	Szerokość radialnych funkcji jąder γ	Szerokość pasma tolerancji ε
0,0026	0,0027	200	0,790	0,820	0,036

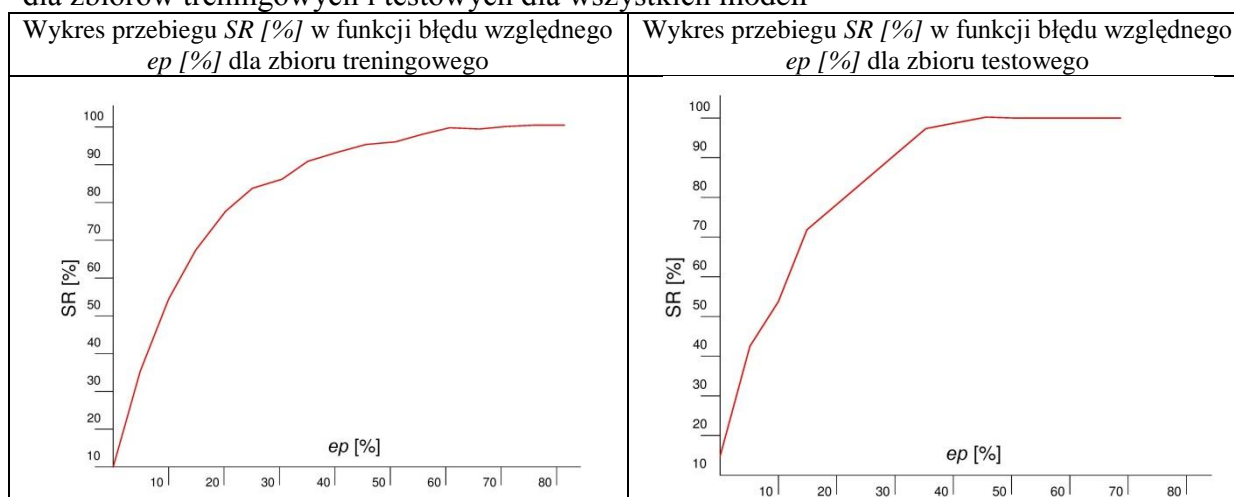
Tabela 2. Wartości błędu V_{er} dla zbioru treningowego i testowego wyrażone w jednostkach zużycia technicznego s_z [%]

Zbiór treningowy	Zbiór testowy
6,05 [%]	6,28 [%]

Tabela 3. Zestawienie wartości miary SR [%] w dziedzinie błędu względnego ep [%] dla zbiorów treningowych i testowych.

Zbiór treningowy		Zbiór testowy	
ep [%]	SR [%]- skumulowany dla $ep < ep_i$	ep [%]	SR [%]- skumulowany dla $ep < ep_i$
0,0	10,2	0	14,4
5,0	34,0	5	40,4
10,0	52,6	10	51,4
15,0	65,0	15	68,5
20,0	74,8	20	76,7
25,0	80,2	25	82,2
30,0	83,4	30	86,3
35,0	87,3	35	93,2
40,0	89,5	40	95,2
45,0	91,7	45	95,2
50,0	92,6	50	96,6
55,0	93,7	55	97,3
60,0	95,3	60	97,3
65,0	95,4	65	97,3
70,0	95,8	70	97,9
75,0	95,9	75	97,9
80,0	96,4	80	97,9
85,0	96,6	85	97,9
90,0	97,0	90	98,6
95,0	97,5	95	99,3
100,0	100,0	100	100,0

Tabela. 4. Wykresy przebiegów miary SR [%] w dziedzinie błędu względnego ep [%] dla zbiorów treningowych i testowych dla wszystkich modeli

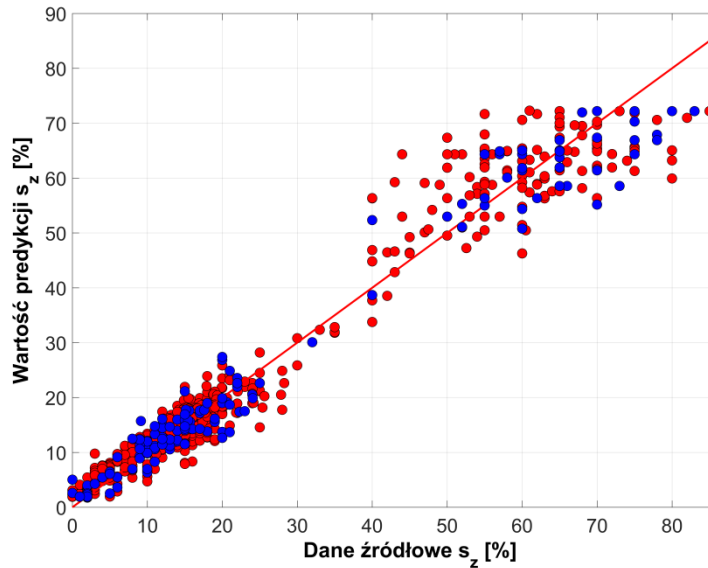


Z analizy wyników zamieszczonych w tabeli 1 można stwierdzić, iż utworzony model cechuje się jednocześnie wysokim poziomem dopasowania oraz generalizacją nabytej wiedzy, o czym świadczą wartości błędów odpowiednio dla zbioru treningowego i testowego. Potwierdzeniem cech generalizacyjnych jest również wyłoniona liczba 200 wektorów podpierających, stanowiąca 33% liczby wszystkich wzorców wykorzystanych do uczenia ze zbioru treningowego. Dodatkową informacją na temat "gładkości" uzyskanego aproksymatora jest relatywnie duża szerokość funkcji jąder $\gamma=0,82$, która dla danych standaryzowanych $N(0,1)$ pozwala na pokrycie w sposób ciągły zakresu wszystkich analizowanych zmiennych.

Analiza wartości błędu V_{er} (por. tab. 2) pozwala ocenić model pod kątem dopasowania i generalizacji. Wartości błędu V_{er} , wyrażone w jednostkach stopnia zużycia technicznego, zarówno dla zbioru treningowego i testowego oscylują koło $\pm 6\%$. Stanowi to dobry wynik w sensie dopasowania predykcji modelu do danych wzorcowych. Ponadto wartości błędu V_{er} dla zbioru treningowego i testowego są bardzo zbliżone, co potwierdza dobre własności generalizacyjne.

Podobnie wnioski przynosi analiza rozkładu miary SR względem błędu względnego ep . W tabeli 3, dla przyjętej granicy błędu względnego ep o wartości 30%, trafność predykcji, wyrażonej miarą SR wynosi odpowiednio 83,4% dla zbioru treningowego i 86,3% dla zbioru testowego. Poziom trafności świadczy o dobrym dopasowaniu modelu do danych wzorcowych. Natomiast zbliżona wartość przebiegu miary SR (por. tab. 4) dla zbioru treningowego i testowego, świadczy o zachowaniu własności generalizacyjnych modelu.

Z kolei zestawienie wartości aproksymowanych względem danych źródłowych (rys. 1) wskazuje, iż współczynnik korelacji między nimi jest bliski 1.

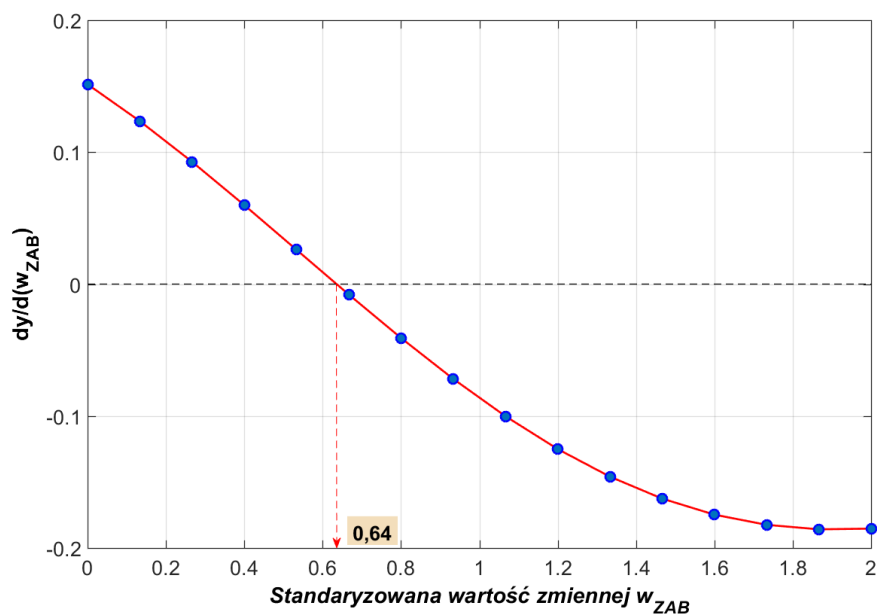


Rys. 1. Rozrzut wartości predykcji modelu względem danych wzorcowych - zbiór treningowy (kolor czerwony), zbiór testowy (kolor niebieski)

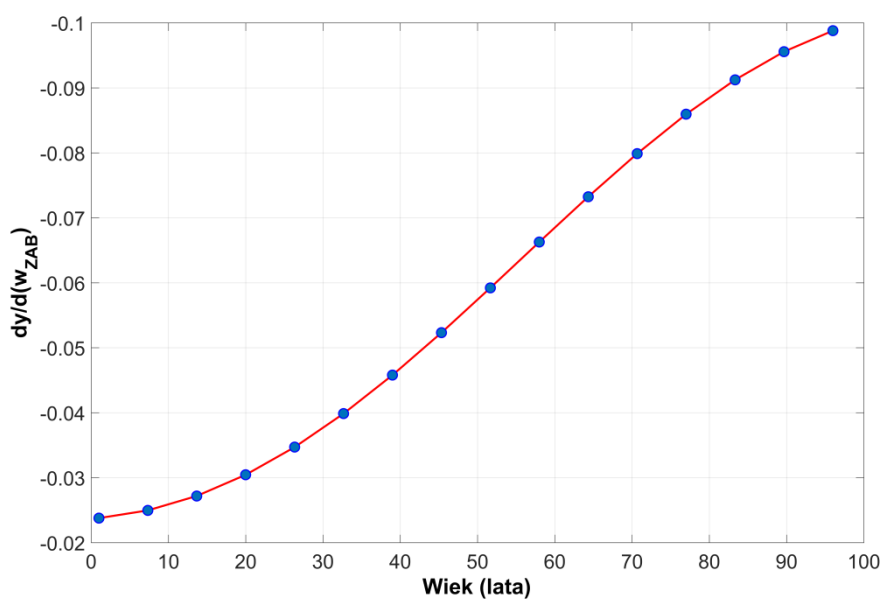
4.2 Badanie wpływu wskaźnika zabezpieczeń w_{ZAB} na zużycie techniczne budynków

W niniejszej pracy, zgodnie z opisem przyjętej metodyki w rozdziale 3.3, problem analizy wpływu wskaźnika zabezpieczeń w_{ZAB} rozwiązano na drodze symulacji modelu dla równomiernie rozmieszczonej siatki punktów w przestrzeni zmiennych wejściowych. Skalę każdej ze standaryzowanych zmiennych podzielono na 20 równych części. Uwzględniając fakt, iż wskaźnik remontowy w_{REM} przyjmował tylko dwie wartości skategoryzowane uzyskano przestrzeń symulacji równą 388962 punktów. W każdym punkcie, zgodnie z zależnością (17), wyznaczona zostały wartości pochodnych cząstkowych względem każdej ze zmiennych ciągłych ujętych w modelu. Uzyskane wartości pochodnych liczonych względem wskaźnika zabezpieczeń w_{ZAB} przedstawiono graficznie na rys. 2 i 3. Na rys. 2 przebieg wartości pochodnej liczonej względem zmiennej w_{ZAB} wskazuje, że modelowana wartość zużycia technicznego budynków wzrasta w przedziale $w_{ZAB} = 0 \div 0,64$. Po przekroczeniu tego zakresu stopień zużycia technicznego zaczyna stopniowo maleć.

Z kolei, na rys. 3 przedstawiono przebieg pochodnej liczonej względem wskaźnika zabezpieczeń w_{ZAB} w domenie zmiennej opisującej wiek budynków. Jak widać, istotność wpływu zabezpieczeń wzrasta wraz z wiekiem budynku powodując obniżenie modelowanej wartości stopnia zużycia.



Rys. 2. Rozkład składowej gradientu dla zmiennej w_{ZAB}



Rys. 3. Rozkład składowej gradientu modelu dla zmiennej w_{ZAB} zilustrowany względem zmiennej opisującej wiek budynków


Analiza uzyskanych wyników prowadzi do następujących wniosków:

- zauważalne obniżenie aproksymowanej wartości zużycia technicznego budynków następuje w momencie, gdy zakres zastosowanych zabezpieczeń podnosi kategorię odporności obiektu (KO) ponad daną kategorię zagrożenia terenu (KT) o wartość względną $w_{ZAB}=0,64$ (por. rys. 2),
- wpływ zabezpieczeń na obniżenie aproksymowanej wartości zużycia technicznego staje się wyraźniejszy wraz z upływem czasu, czyli wzrostem jego zużycia naturalnego (por. rys. 3).

4.3. Badanie wpływu wskaźnika remontowego w_{REM}

Wykorzystywany w pracy wskaźnik remontowy w_{REM} jest zmienną skategoryzowaną. Aby ocenić wpływ tego wskaźnika, utworzony model poddano symulacji z wykorzystaniem dwóch zestawów danych. Jeden charakteryzował budynki nieremontowane, drugi remontowane. Pozostałe wartości zmiennych dla obu przypadków były takie same, co pozwoliło na porównanie przebiegów zużycia technicznego i wyciągnięcie wniosków. Jako miarę wpływu przyjęto wartość różnicy pomiędzy uzyskaną predykcją dla pierwszego zestawu danych (budynki nieremontowane) oraz dla zestawu drugiego. Wyniki różnic zestawiono w dziedzinie zmiennej opisującej wiek budynków i przedstawiono na rysunku 4.

Z analizy wyników przedstawionych na rys. 4 wynika, iż prace remontowe wyraźnie wpływają na obniżenie stopnia zużycia technicznego. Widać również, iż wpływ ten związany jest z wiekiem budynku. Zmiana wartości różnic pomiędzy predykcją modelu dla budynków nieremontowanych i remontowanych, dochodzi do 8% dla budynków wieku ponad 90 lat (por. rys. 4).



Rys. 4. Aproxymowane wartości zużycia technicznego wyznaczone dla zbioru danych wzorcowych z podziałem na budynki remontowane (kolor żółty) i nieremontowane (kolor niebieski)

5. Podsumowanie i wnioski końcowe

Zaprezentowane w pracy wyniki badań pozwalają na wysunięcie wniosków zarówno w aspekcie stosowalności metody SVM dla celów modelowania zużycia technicznego budynków, jak również wpływu z jakim poszczególne zmienne oddziałują na przebieg modelowanego zjawiska.

Stwierdzono, iż metoda SVM pozwala na budowę modelu realizującego nieliniowe odwzorowanie wielowymiarowej dziedziny zmiennych wejściowych na aproksymowaną wartość zużycia technicznego. Model ten zachowuje wymagany poziom dokładności i generalizacji. Ponadto, pomimo braku zadawania pierwotnej funkcji aproksymującej, reprezentatywna dla modelu postać matematyczna pozwala na przeprowadzenie analizy wrażliwości względem zmiennych ciągłych.

W wyniku analizy wpływu zabezpieczeń konstrukcyjnych na zużycie techniczne badanej grupy budynków, ustalono granicę istotnego wpływu zabezpieczeń równą $w_{ZAB}=0,64$.

Uzyskana wartość, zgodnie z zależnością (1) pokazuje, że poziom zabezpieczeń staje się istotny wówczas, gdy kategoria odporności danego budynku, po zastosowaniu zabezpieczeń uzyskuje wartość KO większą od KT o 0,64. Uogólniając można przyjąć, że zabezpieczenia wnoszą poprawę stanu technicznego budynku, gdy powodują przewyższenie kategorii odporności KO nad kategorię zagrożenia terenu KT o przynajmniej 1 kategorię. Informacja ta może być bardzo przydatna przy ocenie tzw. *szkód górniczych*.

Wykorzystując symulację modelu *SVM* wykazano również poziom wpływu wskaźnika remontowego w_{REM} na zużycie techniczne badanych budynków. Prace remontowe, w zależności od wieku budynków, powodują poprawę stanu technicznego w granicach od 0 do 8%.

Z analizy literatury wynika, że metodę *SVM* stosować można również w przypadkach aproksymowania powierzchni odpowiedzi konstrukcji w analizach niezawodnościowych [1]. Biorąc to pod uwagę, planowane jest zastosowanie tej metodyki w odniesieniu do oceny zagrożenia obiektów budowlanych na terenach górniczych na kanwie teorii niezawodności.

Artykuł opracowano w ramach badań statutowych AGH nr 11.11.150.005

Spis literatury

1. Alibrandi, U., Alani, A. M., & Ricciardi, G. (2015). A new sampling strategy for SVM-based response surface for structural reliability analysis. *Probabilistic Engineering Mechanics*, 41, 1-12.
2. Bierlaire M. (2015). *Optimization: principles and algorithms*. EPFL Press
3. Chandrashekar, G., & Sahin, F. (2014). A survey on feature selection methods. *Computers & Electrical Engineering*, 40(1), 16-28.
4. Chang C-C., Lin C-J. (2011) LIBSVM: a library for support vector machines. *ACM Transactions on Intelligent Systems and Technology*, 2(3):27:1–27:27. Software available at <http://www.csie.ntu.edu.tw/~cjlin/libsvm>.
5. Cortez, P., & Embrechts, M. J. (2013). Using sensitivity analysis and visualization techniques to open black box data mining models. *Information Sciences*, 225, 1-17.
6. Firek K., Wodyński A. (2007). Wpływ zabezpieczeń profilaktycznych oraz remontów na zużycie tradycyjnej zabudowy terenów górniczych (The influence of preventive security measures and renovation works on the wear of traditional buildings in mining areas). *The scientific research problems of building*. Pt. 3, praczbiorowa pod red. M. Broniewicza, J. Prusiel. Wydawnictwo Politechniki Białostockiej, ISBN 978-83-60200-33-9.
7. Firek K., Rusek J., Wodyński A. (2015). Assessing the influence of mining impacts on technical wear of masonry buildings using multiple regression analysis. *International Multidisciplinary Scientific GeoConference SGEM*. Albena, Bulgaria.
8. Guo Y-M., Wang X-T., Chong L., Zheng Y-F., Cai X-B. (2014). Diagnostyka uszkodzeń układu elektronicznego z wykorzystaniem Wielojądrowej Maszyny Wektorów Nośnych (SVM) zoptymalizowanej przy pomocy poprawionego algorytmu CPSO. *Electronic System Fault Diagnosis with Optimized Multi-kernel SVM by Improved CPSO*. *Eksploatacja i Niezawodność – Maintenance and Reliability 2014*; 16(1): 85–91
9. Instrukcja GIG nr 12 2000: Zasady oceny możliwości prowadzenia podziemnej eksploatacji górniczej z uwagi na ochronę obiektów budowlanych (Guideline GIG 12 2000: Principles for Evaluating opportunities for underground mining for the protection of buildings. Katowice 2000.

10. Jankowski N., Grabczewski K. (2003). Toward optimal SVM. The third IASTED International Conference on Artificial Intelligence and Applications, Anaheim, Calgary, Zurich. The International Association of Science and Technology for Development, ACTA Press.
11. Kuźniar, K. (2004). Analiza drgań budynków ścianowych o średniej wysokości podlegających wstrząsom górniczym z wykorzystaniem sieci neuronowych.
12. Liao, P., Zhang, X., Li, K., Fu, Y., Wang, M., & Wang, S. (2015). Parameter Optimization for Support Vector Machine Based on Nested Genetic Algorithms. *Journal of Automation and Control Engineering* Vol, 3(6).
13. Lin, X., Yang, F., Zhou, L., Yin, P., Kong, H., Xing, W., ... & Xu, G. (2012). A support vector machine-recursive feature elimination feature selection method based on artificial contrast variables and mutual information. *Journal of Chromatography B*, 910, 149-155.
14. Łęski J. (2008). *Systemy neuronowo-rozmyte*. WNT, Warszawa.
15. MATLAB and Genetic Toolbox 2015b, The MathWorks, Inc., Natick, Massachusetts, United States
16. Osowski S. (2015). *Metody i narzędzia eksploracji danych*. BTC. Legionowo.
17. Rojek I., Studziński J. (2014). Porównanie różnych typów sieci neuronowych do lokalizacji awarii w sieciach wodociągowych. Comparison of different types of neuronal nets for failures location within water-supply networks. *Eksploracja i Niezawodność – Maintenance and Reliability 2014*; 16(1): 42–47
18. Rueda I.E.A, Arciniegas F.A. (2004). SVM Sensitivity Analysis: An Application to currency Crises Aftermarks. *IEEE trans. Systems, Man and Cybernetics*. Vol 34. No. 3.
19. Rusek J. (2009). Developing a model of the course of technical wear of building structures in mining areas using the method of Support Vector Machine in regression approach. X Days of Mining Metrology and Protection of Mining Areas. Cracow, 28–29.05.2009. Academic Scientific Publishing House of AGH University of Science and Technology in Cracow. Cracow.
20. Russell S., Norvig P. (2010). *Artificial Intelligence: A Modern Approach* (3rd ed.). Upper Saddle River: Prentice Hall. ISBN 9780136042594.
21. Schölkopf B., Smola A.J. (2002). *Learning with Kernels*. MIT Press. Cambridge, Massachusetts.
22. Tikka J., Hollmen J. (2008). Selection of important input variables for RBF network using partial derivatives - ESANN'2008 proceedings, European Symposium on Artificial Neural Networks-Advances In Computational Intelligence and Learning. Bruges (Belgium).
23. Wodyński A. (2007). Zużycie techniczne budynków na terenach górniczych (The process of technical wear of buildings in mining areas). Uczelniane Wydawnictwa Naukowo-Dydaktyczne, Akademia Górniczo-Hutnicza im. Stanisława Staszica w Krakowie, Kraków 2007.
24. Wodyński A., Lasocki S. (2002). Conception Of Assessment Of Mining Tremor Effects On Technical Wear Of Buildings. *Acta Montana, series A*, nr 21 (125), Praha.
25. Vapnik V. (1998). *Statistical learning theory*. John Wiley & Sons, New York.
26. Yeh, I. C., & Cheng, W. L. (2010). First and second order sensitivity analysis of MLP. *Neurocomputing*, 73(10), 2225-2233