

Mariusz Kalita*, Waldemar Wójcik*

Regulacja procesu spalania z wykorzystaniem SSN oraz algorytmów ewolucyjnych

1. Wprowadzenie

W przeszłości główną miarą pracy kotła była ilość wyprodukowanej pary o zadanych parametrach. Podejście takie powodowało duże zanieczyszczenie środowiska poprzez emisję szkodliwych substancji. Obecnie zwiększenie znaczenia ochrony środowiska oraz wzrost wymagań dotyczących emisji związków chemicznych i gazów do atmosfery spowodowało konieczność intensyfikacji prac modernizacyjnych mających na celu spełnienie, przez istniejące już elektrownie i elektrociepłownie, stosunkowo ostrych norm emisyjnych. W niniejszej pracy przedstawione zostały wyniki badań nad zastosowaniem technik optymalizacji globalnej oraz sztucznej inteligencji w regulacji procesem spalania w kotle energetycznym.

2. Obecny stan techniki

Metody ograniczania emisji zanieczyszczeń podczas procesu spalania węgla w kotłach pływowych, można generalnie podzielić na dwie grupy:

- pierwotne, które mają na celu eliminację szkodliwych substancji jeszcze w obrębie komory paleniskowej, poprzez niedopuszczenie do ich powstawania bądź wiążąc je przed opuszczeniem komory;
- wtórne, obejmujące redukcję szkodliwych substancji powstałych w wyniku spalania poza komorą paleniskową, zazwyczaj w osobnych komorach i instalacjach.

Ze względu na wysokie koszty metod wtórnych, prace badawcze w głównej mierze skierowane zostały na metody pierwotne, których skutkiem było wprowadzenie do energetyki tzw. spalania niskoemisyjnego będącego spalaniem strefowym. Najbardziej znaczącą zaletą tych zmian było ograniczenie emisji NO_x do poziomu określonego przez normy, przy

* Politechnika Lubelska w Lublinie

względnie niskich nakładach inwestycyjnych. Niestety ograniczenie emisji NO_x przez zmianę procesu spalania pociąga za sobą negatywne skutki dla eksploatacji kotła. Zatem konieczne było sterowanie procesem tak, aby zminimalizować negatywne oddziaływanie na kocioł oraz utrzymać żądany poziom NO_x . Obecnie do sterowania wykorzystywane są pomiary uśrednione i opóźnione. Pomiar składu chemicznego gazów najczęściej dokonywany jest za pomocą analizatorów gazów umieszczonych za obrotowymi podgrzewaczami powietrza lub w kominie. Niewątpliwą zaletą takiego sposobu pomiaru jest łatwość interpretacji wyników analizy, jednakże opóźnienie powoduje, że sterowanie jest często za mało efektywne. Ponieważ indywidualny nadmiar powietrza w każdym z palników decyduje o ilości NO_x generowanych w kotle węglowym, istnieje potrzeba objęcia pętlą regulacji pojedynczego palnika.

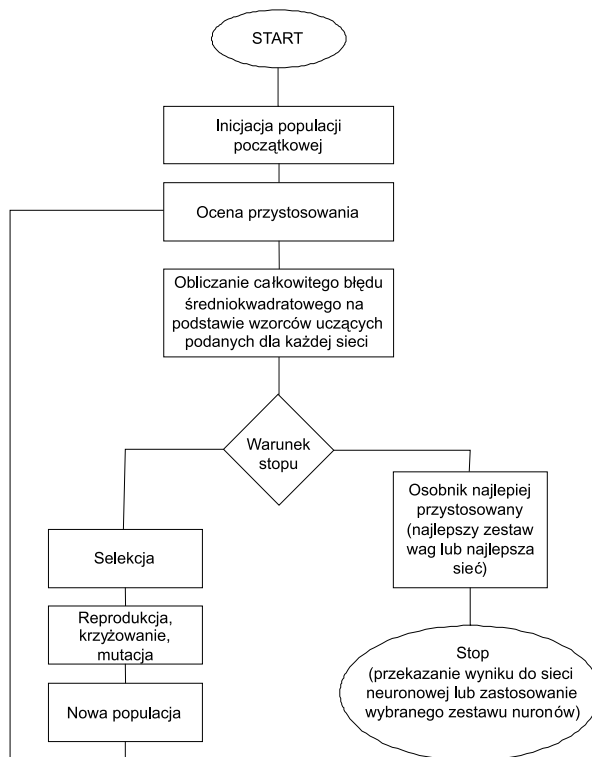
Analiza przedstawionego problemu praktycznej kontroli procesu spalania w warunkach przemysłowych pozwoliła na opracowanie w Katedrze Elektroniki Politechniki Lubelskiej odpowiedniego układu monitorowania tego procesu. Układ ten wykorzystuje informacje zawarte w natężeniu promieniowania emitowanego przez płomień. Zaletą takiego podejścia jest praktycznie brak opóźnienia podczas wykonywania pomiaru. Opracowane urządzenie umożliwia selektywną kontrolę płomienia pojedynczego palnika w obecności zakłóceń, których źródłem są płomienie palników sąsiednich oraz zapylenie.

3. Zastosowanie algorytmów ewolucyjnych

Do rozwiązania problemu sterowania procesem spalania w kotle energetycznym zdecydowano się zastosować algorytmy ewolucyjne (AE), a dokładnie wykorzystano ich podgrupę, tj. algorytmy genetyczne (AG). Podstawą algorytmów ewolucyjnych jest zbiór zasad naturalnej ewolucji organizmów. W przyrodzie największą szansę na przeżycie mają organizmy najlepiej przystosowane do środowiska. Sposób ewolucji nowego pokolenia oparty na obserwacji natury składa się z trzech operacji: selekcji, krzyżowania i mutacji.

W pierwszym etapie pracy AG dokonywany jest proces selekcji osobników, w wyniku którego powstaje pula osobników rodzicielskich. Po zakończeniu procesu selekcji wykonujemy krzyżowanie, które przebiega w dwóch etapach. Na początku kojarzymy w sposób losowy osobniki z puli rodzicielskiej. Następnie każda para przechodzi proces krzyżowania, który polega na losowym określeniu miejsca podziału chromosomów rodziców oraz na odpowiednim ich połączeniu. W ten sposób otrzymujemy dwoje potomków, których materiał genetyczny jest wymieszany materiałem genetycznym ich rodziców. Operacja mutacji polega na przypadkowej (zachodzącej z niewielkim prawdopodobieństwem) zmianie wartości elementu chromosomu. Prawdopodobieństwo mutacji określa się na poziomie jeden do tysiąca. Jest to więc operacja drugorzędna w porównaniu z reprodukcją i krzyżowaniem, jednak stosowanie jej jest konieczne, ponieważ mogłoby się zdarzyć, że pewne fragmenty optymalnego rozwiązania nie znajdują się w genomie żadnego osobnika z populacji początkowej lub będą występowały jedynie u organizmów słabo przystosowanych do śro-

dowiska. Takie organizmy w procesie ewolucji zostaną szybko zastąpione przez organizmy lepiej przystosowane. W takich sytuacjach mutacja pozwala wprowadzić do przetwarzanej puli genów nowe elementy, które jeśli okażą się korzystne, rozprzestrzenia się na większość populacji. Dlatego też mutacja, stosowana rozsądnie i z umiarem, może istotnie poprawić wyniki osiągnięte przy stosowaniu AG (rys 1).



Rys. 1. Schemat działania algorytmu genetycznego

4. Algorytmy genetyczne w sieciach neuronowych

W niniejszej pracy wykorzystano połączenie dwóch metod: algorytmów genetycznych i sieci neuronowych. W opisywanym przypadku AG zastosowano do uczenia sieci neuronowej. W większości przypadków działanie takiego algorytmu polega na optymalizacji wag sieci neuronowej z zaprojektowaną wcześniej topologią. Każdy przedstawiciel populacji jest opisany przez zbiór wag sieci, a następnie poddawany ocenie przez funkcję przystosowania. Funkcja przystosowania jest zdefiniowana jako różnica pomiędzy wartością zadaną a otrzymaną na wyjściu dla różnych danych wejściowych. Zastosowanie AG w tym

przypadku ma dwie najważniejsze zalety. Po pierwsze, pozwala na globalne przeszukiwanie przestrzeni wag, dzięki czemu możliwe jest uniknięcie zbyt szybkiej zbieżności (utknięcia), oraz, po drugie, można ją stosować, gdy dane o gradiencie są niedostępne.

5. Dobór mechanizmów wspomagających pracę AE

5.1. Dobór operatora selekcji

Najlepiej przystosowane osobniki mają największą szansę na przetrwanie i uzyskanie potomstwa, a co za tym idzie, powielenia najlepszych cech. Prowadzi to do stałej poprawy adaptacji populacji.

Podczas symulacji testom zostały poddane następujące rodzaje selekcji:

- reprodukcja proporcjonalna,
- reprodukcja turniejowa,
- reprodukcja progowa,
- sukcesja z całkowitym zastępowaniem,
- sukcesja z częściowym zastępowaniem.

Reprodukcja proporcjonalna polega na zdefiniowaniu zmiennej losowej określającej dla każdego osobnika prawdopodobieństwo wylosowania. Prawdopodobieństwo to jest proporcjonalne do jego funkcji przystosowania. Stąd możemy oczekiwać, że stosunek liczby kopii w nowej populacji osobników z populacji bazowej jest równy stosunkowi wartości przystosowania tych osobników.

Reprodukcja rangowa, w której prawdopodobieństwo wybrania osobnika zależy od jego rangi przystosowania na tle populacji bazowej. Ranga nadawana jest zazwyczaj dwoma sposobami, tj. osobniki są szeregowane według wartości rang lub osobniki o jednakowym przystosowaniu otrzymują tę samą rangę.

Reprodukcja turniejowa, w której wybór osobników przeprowadza się w dwóch etapach. W pierwszym tworzy się grupę turniejową z osobników populacji bazowej, a następnie przeprowadza się turniej pomiędzy wybranymi wcześniej osobnikami. Wygrywają osobniki posiadające największą wartość funkcji przystosowania, po czym są kopiowane do populacji potomnej.

Reprodukcja progowa jest przypadkiem reprodukcji rangowej i polega na określeniu funkcji progowej, w której ważną rolę odgrywa wskaźnik nacisku selektywnego, gdyż od niego zależy liczność potomstwa pojedynczego osobnika.

Sukcesja z całkowitym zastępowaniem jest najpopularniejszą metodą wykorzystywaną przez programistów i polega na tym, że populacja potomna staje się populacją bazową.

Sukcesja z częściowym zastępowaniem jest bardziej złożoną odmianą poprzednio opisywanej sukcesji i polega na tym, że nowa populacja bazowa zawiera zarówno osobniki ze starej populacji bazowej, jak i osobniki z populacji potomnej.

W wyniku serii doświadczeń do przeprowadzenia selekcji wybrano metodę turniejową. Metoda turniejowa nadaje się zarówno do problemów maksymalizacji, jak i minimalizacji funkcji.

Oprócz tego może być łatwo rozszerzona na zadania dotyczące optymalizacji wielokryterialnej. W metodzie turniejowej można zmieniać rozmiar podgrup, na jakie dzielona jest populacja.

5.2. Mechanizm niszczenia

W naturalnym środowisku selekcja jest podstawowym mechanizmem wywołującym rywalizację wśród osobników. Najlepiej przystosowane osobniki mają największą szansę na przetrwanie i uzyskanie potomstwa, a co za tym idzie – powielenia najlepszych cech. Prowadzi to do stałej poprawy adaptacji osobników w populacji. Jednak podczas tych procesów czasami pojawiają się osobniki ze znacznie słabszym przystosowaniem i mniejszym prawdopodobieństwem przetrwania. Dla całego środowiska takie osobniki mogą stanowić źródło różnorodności i przystosowania osobników do nowych warunków, można tu powiedzieć, że tworzą się nowe gatunki. W środowisku czas życia takiego gatunku jest krótki i należy podjąć szczególne działania, aby go ochronić. Teoria ta znalazła zastosowanie w algorytmach ewolucyjnych jako technika niszczenia polegająca na utrzymywaniu różnorodności osobników lepiej i słabiej przystosowanych. Nisze to grupy osobników o podobnych cechach fenotypowych posiadających najczęściej podobne przystosowanie. Stopień pokrewieństwa określany jest funkcją bliskości, a jej argumentem jest geometryczna odległość między rozważanymi osobnikami.

W zastosowanym mechanizmie niszczenia dokonano modyfikacji wektora stopnia przystosowania każdego osobnika znajdującego się w niszy oraz w następnym kroku przetestowane zostało niszczenie rang osobników. Obliczenia wykonane zostały z zastosowaniem poniższych wzorów.

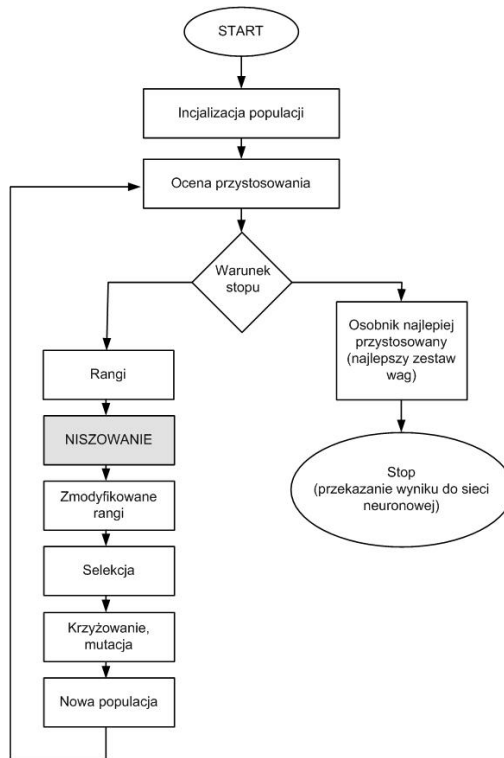
$$\tilde{f}(x_i) = \frac{f(x_i)}{\sum_{j=1}^N \delta_{ij}} \quad \text{lub} \quad \tilde{\rho}(x_i) = \frac{\rho(x_i)}{\sum_{j=1}^N \delta_{ij}},$$

gdzie:

- $f(x_i)$ – wektor stopnia przystosowania osobnika,
- $\rho(x_i)$ – skalarna ranga przystosowania osobnika,
- $\tilde{f}(x_i)$ oraz $\tilde{\rho}(x_i)$ – reprezentacja wektora niszczonego i jego skalarna ranga,
- δ_{ij} – efektywna liczba osobników w niszy o środku opisanym przez fenotyp rozważanego i -tego osobnika.

Po zaadoptowaniu mechanizmów niszczenia schemat algorytmu genetycznego przedstawia się jak na rysunku 2.

Celem zastosowania niszczenia było zapobieżenie przedwczesnej zbieżności algorytmu w sytuacji pojawiania się zaburzeń w obiekcie symulacyjnym. Proces niszczenia pomimo że wymaga więcej czasu na przeprowadzenie koniecznych obliczeń jest znacznie dokładniejszy w wyszukiwaniu i prognozowaniu rozwiązań [7].

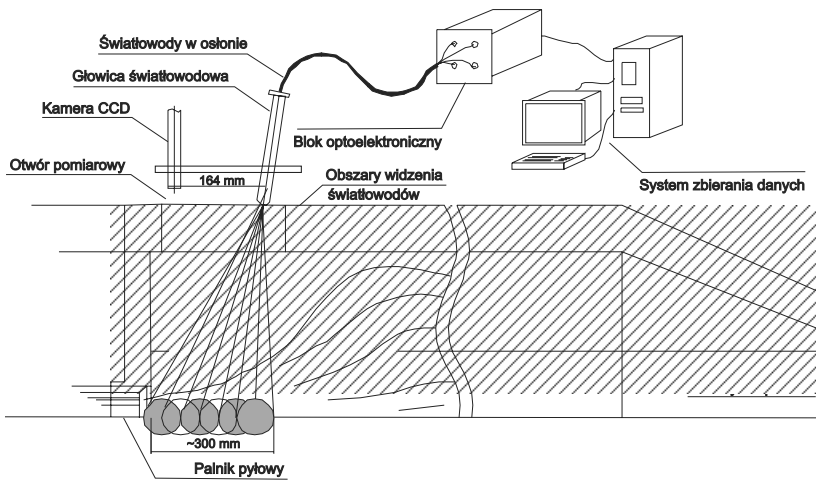


Rys. 2. Modyfikacja AG z użyciem niszowania przystosowania

6. Symulacja zastosowania zmodyfikowanego algorytmu genetycznego

W opisywanym przykładzie zastosowano zmodyfikowany AG wspomagający działanie sieci neuronowej. Zanim jednak przystąpiono do eksperymentu należało zidentyfikować obiekt, który miał być poddany sterowaniu oraz zaproponować sieć neuronową. Identyfikacja obiektu dynamicznego polega na znalezieniu matematycznego opisu modelu na podstawie serii pomiarów. Znajomość dokładnego opisu matematycznego obiektu lub budowa jego symulatora daje możliwość opracowania układów sterowania, które w porównaniu z układami opracowanymi bez takiej wiedzy o obiekcie są mniej efektywne. Uwzględniając ogromną wagę tych problemów w automatyce, dotychczasowe badania teoretyczne i aplikacyjne były prowadzone głównie w zakresie problemów modelowania matematycznego. Wynikiem intensywnych badań prowadzonych w tym kierunku od początku lat sześćdziesiątych jest opracowanie całego szeregu metod. Pomimo tego, że wszystkie obiekty są w zasadzie nieliniowe, opracowana teoria identyfikacji dotyczy przede wszystkim liniowych obiektów statycznych i dynamicznych. W wyniku przeprowadzonych badań opracowany został model panika energetycznego w oparciu o perceptron trójwarstwowy z jedną warstwą ukrytą [5].


Pomiary oraz część eksperymentów wykonywana była na laboratoryjnej komorze spalania (rys. 3) znajdującej się w Instytucie Energetyki w Warszawie. Symulacje z zastosowaniem algorytmu zostały przeprowadzone z wykorzystaniem oprogramowania specjalnie do tego celu przygotowanego, a układem wejściowym był zaproponowany w pracy [5] neuronowy regulator pracy palnika pyłowego, którego zadaniem jest regulacja stężenia zawartości NO_x powstającego w procesie spalania. Poniżej przedstawiono wyniki symulacji zastosowania adaptacyjnego regulatora neuronowego wspomaganego przez algorytm genetyczny. Jako kryterium oceny jakości pracy regulatora przyjęto minimalną odchyłkę od wartości zadanej.



Rys. 3. Schemat aparatury pomiarowej

Źródło: Instytut Energetyki Warszawa

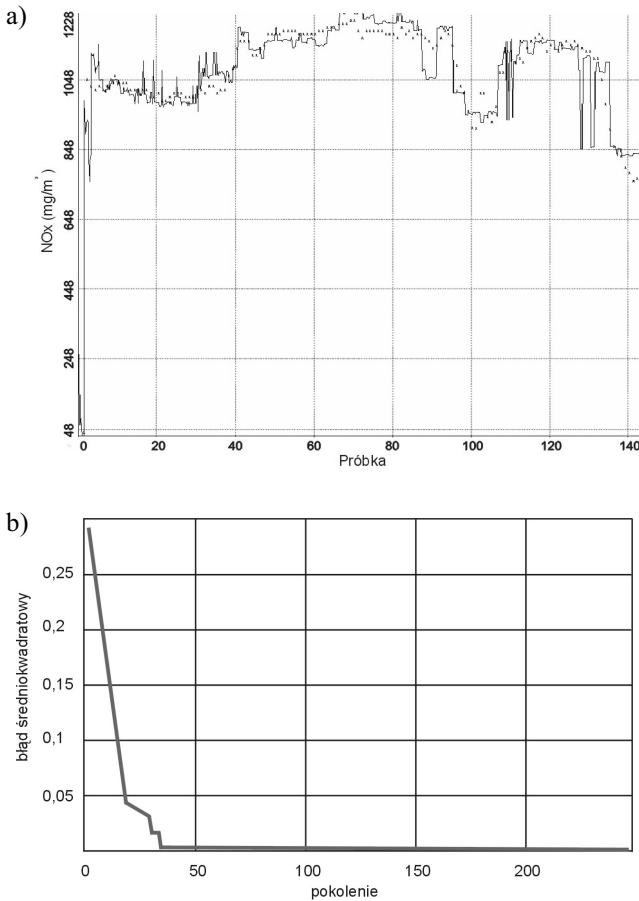
Rysunek 4 przedstawia wyniki badań przeprowadzonych za pomocą dwóch urządzeń pomiarowych. W pierwszym przypadku jest to analizator gazów, drugim zestawem pomiarowym był optyczny system monitorowania płomienia wykonany w laboratorium Wydziału Elektrotechniki i Informatyki Politechniki Lubelskiej.



Rys. 4. Wynik pomiaru przeprowadzony za pomocą sondy optycznej (linia przerywana), oraz konwencjonalnej aparatury pomiarowej (linia ciągła) [5]

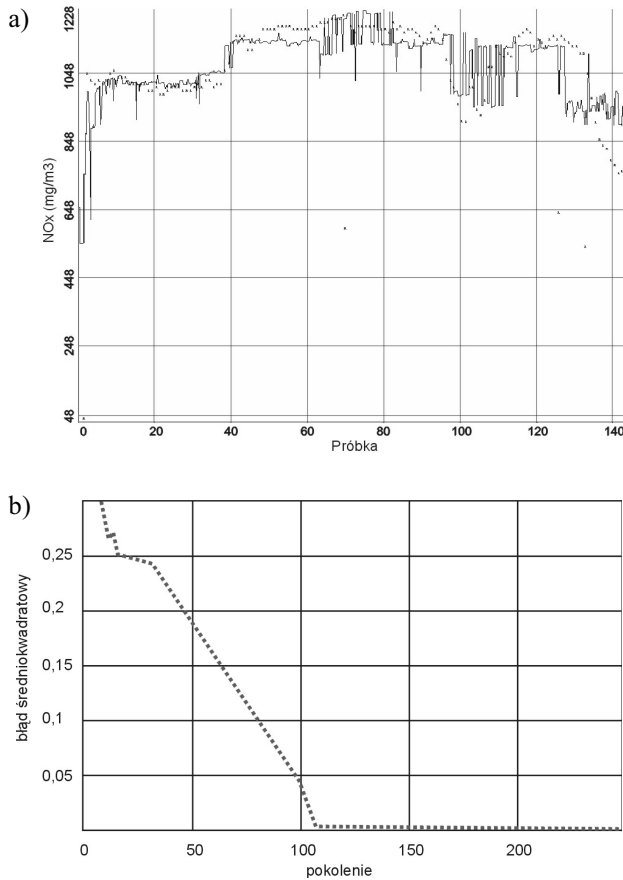
Rysunki 5 i 6 przedstawiają symulację pracy regulatora neuronowego wspomaganego przez zmodyfikowany algorytm genetyczny. Doświadczenie przeprowadzono w następujących warunkach:

- liczba osobników w populacji początkowej wynosiła 50,
- selekcja osobników przeprowadzona została za pomocą przedstawionych wcześniej metod z użyciem sukcesji z całkowitym zastępowaniem,
- dobrano współczynniki operatorów krzyżowania i mutacji,
- procent mutowanych osobników 20%,
- procent krzyżowanych osobników 25%,
- błąd aproksymacji liczony na podstawie kwadratu różnicy,
- wykonano 250 iteracji algorytmu.



Rys. 5. Wynik symulacji współpracy zmodyfikowanego algorytmu ewolucyjnego z regulatorem neuronowym – reprodukcja turniejowa
Objaśnienia w tekście

Na rysunkach 5a i b zaprezentowano wynik pracy testowanego regulatora z wykorzystaniem w reprodukcji turniejowej. Linia kropkowana (rys. 5a) przedstawia pracę regulatora neuronowego z pracy [5]. Natomiast linia ciągła odzwierciedla wynik działania regulatora opartego na sztucznej sieci neuronowej wspomaganą przez algorytm genetyczny. Zśród wielu typów operatorów selekcji przedstawionych w punkcie 5.1 do zaprezentowania wybrano reprodukcję turniejową. Związane jest to z tym, że ten typ reprodukcji daje najlepsze rezultaty w przedstawionym powyżej zadaniu tzn. po kilkunastu uruchomieniach algorytmu każdorazowo rozwiązanie uzyskiwano przed pięćdziesiątą generacją.



Rys. 6. Wynik symulacji współpracy zmodyfikowanego algorytmu ewolucyjnego z regulatorem neuronowym – niszczenie rangi osobników oraz wykres zbieżności
Objaśnienia w tekście

Na rysunkach 6a i b zaprezentowano wynik pracy testowanego regulatora. Linia kropkowana (rys. 6a) przedstawia pracę regulatora neuronowego z pracy [5]. Natomiast linia ciągła odzwierciedla wynik działania regulatora opartego na sztucznej sieci neuronowej

wej wspomaganej przez algorytm genetyczny z zastosowaniem niszowania rangi osobników. Jest to próba zastosowania mechanizmów niszowania w zagadnieniu poszukiwania najlepszych parametrów regulatora neuronowego. Wprowadzenie techniki niszowania wydłużyło czas obliczeń i odnalezienie najlepszego rozwiązania, jednak jej brak powodował iż w sytuacji wystąpienia znacznego zaburzenia w obiekcie algorytm nie potrafił znaleźć optymalnego rozwiązania przez co nastawy regulatora stawały się chaotyczne. Obecnie przygotowywane są testy z wykorzystaniem estymatora zarówno tlenków azotu (NO_x), jak i tlenku węgla (CO) gdzie wg wstępnych szacunków technika ta będzie bardziej skuteczna niż w powyższym zastosowaniu.

7. Wnioski

Zaprezentowane wyniki pozwalają stwierdzić, że zastosowanie algorytmów ewolucyjnych w procesie regulacji stężenia NO_x w kotle energetycznym daje obiecujące rezultaty oraz perspektywy rozwoju światłowodowych czujników jakości spalania. Niszowanie rangi osobników oraz prawidłowy dobór operatora selekcji pozwala zwiększyć szanse oraz szybkość znalezienia optymalnego rozwiązania w środowisku dynamicznym zapobiegając jednocześnie przedwczesnej zbieżności. Oczywiście wymagają one jeszcze dopracowania szczególnie w części programistycznej, ale już dziś możemy przypuszczać, że modyfikowane algorytmy ewolucyjne będą mieć dominującą rolę w zastosowaniach dla adaptacyjnych systemów sterowania. Jak pokazały doświadczenia, zastosowanie niszowania oraz selekcji turniejowej w tym przypadku daje lepsze rezultaty, tzn. AG w krótszym czasie uzyskuje zbieżność.

Literatura

- [1] Arabas J., *Wykłady z algorytmów ewolucyjnych*. Warszawa, WNT 2001.
- [2] Goldberg D.E., *Algorytmy genetyczne i ich zastosowania*. Warszawa, WNT 2003.
- [3] Michalewicz Z., *Algorytmy genetyczne + struktury danych = programy ewolucyjne*. Warszawa, WNT 1996.
- [4] Rutkowska D., Piliński M., Rutkowski L., *Sieci neuronowe, algorytmy genetyczne i systemy rozmyte*. Warszawa-Łódź, PWN 1997.
- [5] Smolarz A., *Neuronowy regulator pracy wirowego palnika pyłowego*. Lublin, Politechnika Lubelska 2003 (praca doktorska).
- [6] Wójcik W., Kalita M., Smolarz A., Pilek B., *Controlling combustion process in power boiler by genetic algorithm and neural network*. Wilga 2004.
- [7] Korbicz J., Kościelny J.M., Kowalczyk Z., Cholewa W., *Diagnostyka procesów. Modele, metody sztucznej inteligencji. Zastosowania*. Warszawa, PWN 2002.