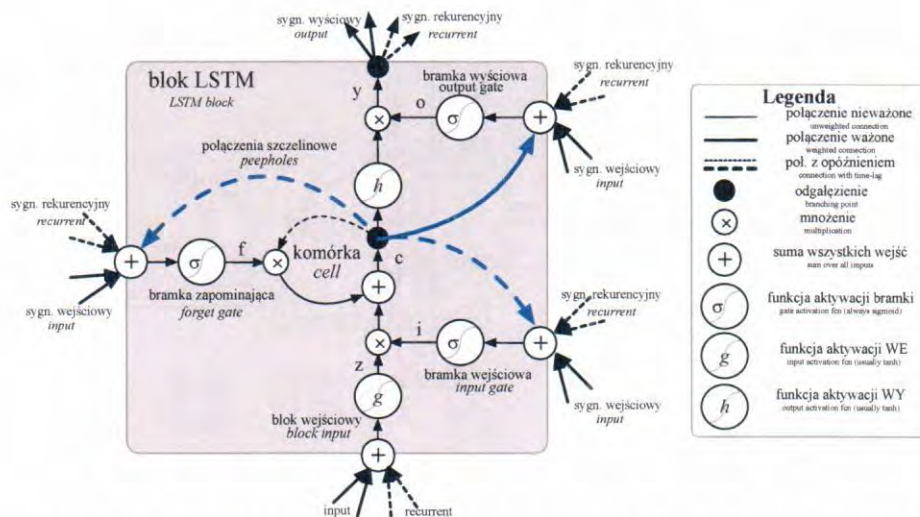


W monografii pt.: „Zaawansowane techniki sterowania procesem spalania pyłu węglowego” dużo uwagi poświęcone zostało wykorzystaniu sztucznych sieci neuronowych w modelowaniu procesu spalania. Dotyczy to przede wszystkim metod głębokiego uczenia. Poza wyborem klasy, struktury i metody uczenia, pojawiają się także możliwości wpływu na proces uczenia poprzez techniki regularyzacji oraz bardziej efektywne funkcje aktywacji. Rekurencyjne sieci neuronowe (RNN) są modelowane na podstawie zachowania występujących w naturze wielu komórek z pamięcią o adresowalnej treści (ang. *content-addressable memory*), zdolną do przechwytywania całej sekwencji informacji, podanej w formie fragmentów. W czasie, gdy sieci „w przód” uruchamiają swoje neurony w jednym kierunku, RNN wykorzystują silne sprzężenie zwrotne. RNNs modelują nieliniowe układy dynamiczne, których dynamika przestrzeni fazowej jest określona przez znaczną liczbę lokalnie stabilnych węzłów [6].

Podczas długoczasowego zapamiętywania kontekstu, gradienty RNN mogą stać się trudne do usunięcia, ponieważ wykorzystują swoje sprzężenia zwrotne do zapamiętania struktury ostatnich wejść. Podobnie, propagujące wstecznie sygnały błędów w czasie mogą mieć duże wartości (powodując oscylacje wag) lub zanikać (utrudniając wyznaczenie wag wolno zmiennych). Zmiany te w czasie propagowanych wstecznie błędów zależą eksponencjalnie od wartości wag [1,3].

Do modelowania procesu spalania w monografii wykorzystano klasyczną strukturę perceptronu wielowarstwowego oraz rozwiązanie *długiej pamięci krótkotrwałej* (ang. *Long Short Term Memory*, LSTM), która odcina gradienty w sieci, wszędzie tam, gdzie jest to nieszkodliwe, a jednocześnie wymusza ciągłe przepływy błędów w specjalnych jednostkach multiplikatywnych (ang. *Multiplicative Units*, MU). Stały przepływ błędów jest regulowany przez nieliniowe MU, które uczą się otwierać lub zamykać bramki w komórce. Schemat działania takiej struktury zamieszczono na rysunku 2.



Rys. 2. Model bloku struktury Long Short-Term Memory (LSTM)

Stanowią one struktury, których bramki zapominania umożliwiają precyzyjne uczenie w czasie.

Analiza procesu spalania w kotłach węglowych ujawnia trzy główne czynniki wpływające niekorzystnie na sprawność kotła. Należą do nich poziom szkalowania

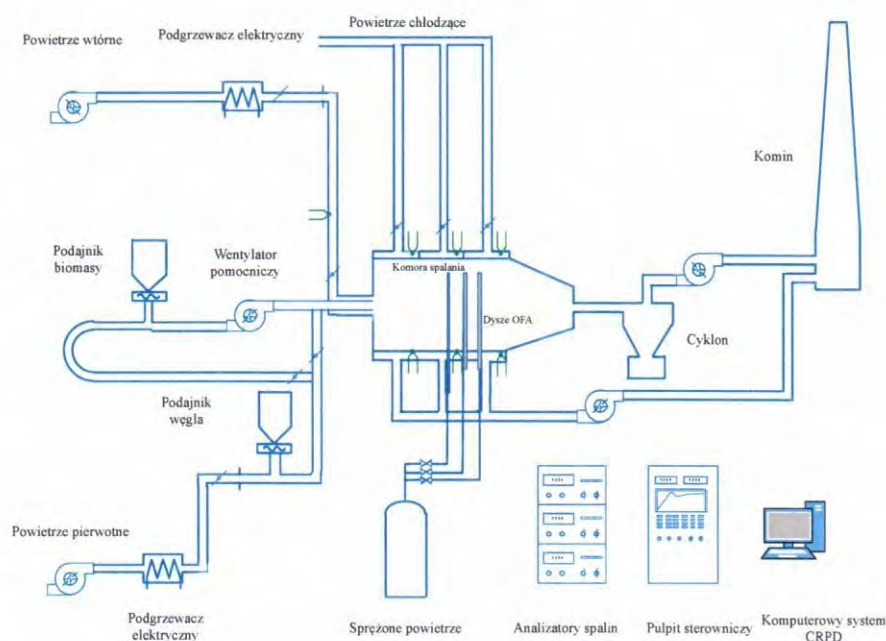
i zanieczyszczenia powierzchni grzejnych oraz przyrządów pomiarowych, straty ciepła spowodowane gazami wylotowymi, a także duży udział niedopału.

Możliwość oceny jakości spalania jest bardzo ważna dla właściwej pracy kotła energetycznego [8]. Rozpatrując proces spalania w energetycznych kotłach pyłowych należy zauważyć, że istotny wpływ na jego przebieg mają: reakcje chemiczne, efektywność przekazywania ciepła, stabilność płomienia oraz intensywność powstawania NO_x i CO. Największy wpływ na aerodynamikę spalania mają palniki oraz rodzaj i sposób podawania paliwa.

Niskoemisyjne palniki pyłowe wykorzystują redukcyjne właściwości bogatego płomienia pyłowego przez organizację stref spalania podstechiometrycznego z wykorzystaniem stopniowania powietrza lub stopniowania paliwa. To z kolei, może pogorszyć stabilność spalania i zwiększyć stratę niedopału.

Uwzględniając te czynniki oraz istotne aspekty ekologiczne, zarysowuje się potrzeba opracowania systemu sterowania procesem spalania, który będzie optymalizował pracę kotła na podstawie informacji uzyskanych z konwencjonalnego oprzyrządowania oraz uwzględni innowacyjne techniki pozwalające na ocenę jakości procesu.

Od strony technologicznej, istotnym parametrem jest zapewnienie stabilności płomienia oraz wykrywanie stanów awaryjnych. Stąd, układ sterowania powinien być uzupełniony o informację diagnostyczną o płomieniu z wykorzystaniem technologii wizyjnych lub sond światłowodowych. Równie istotne znaczenie mają ilościowe informacje odnośnie stężeń tlenków azotu, tlenków węgla oraz dwutlenku siarki w celu spełnienia ograniczeń normatywnych.



Rys. 3.. Schemat ilustrujący stanowisko do badania procesów spalania

Trudny w określeniu, ale przynoszący cenną informację o parametrach wejściowych procesu jest ciągły pomiar przepływu pyłu w pyłoprzewodach. Podobnie, ale na wyjściu procesu, kluczowe byłoby pozyskanie informacji w trybie on-line na temat zawartości części palnych w popiele i żużlu (zwłaszcza zawartości węgla organicznego). Dla uzyskania

tej informacji niezbędne jest przeprowadzenie pomiarów na rzeczywistym obiekcie z wykorzystaniem kosztownej aparatury pomiarowej.

Użycie wspomnianych informacji w rozwiązaniach zaproponowanych w monografii było możliwe dzięki pracom badawczym realizowanym w Instytucie Energetyki w Warszawie, na stanowisku doświadczalnym do badań procesu spalania o mocy cieplnej 0,5 MW z wykorzystaniem palnika pyłowego. Schemat stanowiska, w konfiguracji do badania procesu współspalania, przedstawiono na rysunku 3.

Główny element stanowiska stanowi cylindryczna komora spalania, której wewnętrzna część wyłożona jest materiałem izolacyjnym, a zewnętrzna chłodzona jest powietrzem. Przednia ściana komory spalania jest chłodzona wodą. W osi ściany przedniej zainstalowano palnik pyłowy. Do wygrzania stanowiska oraz zapalenia paliwa pyłowego używany jest pomocniczy palnik olejowy. Do palnika pyłowego doprowadzone jest powietrze pierwotne w ilości 250 m³N/h oraz wtórne – do 500 m³N/h.

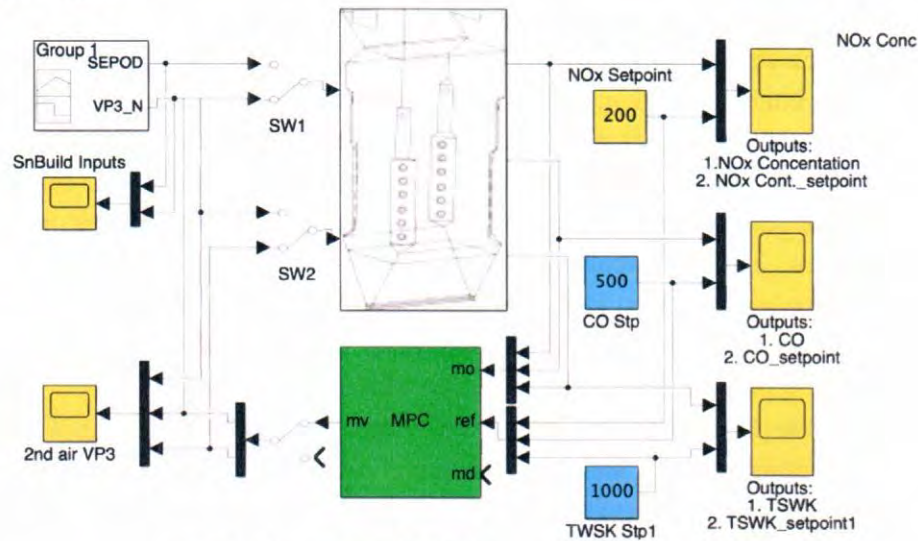
Przeprowadzenie identyfikacji parametrów modelu procesu spalania dla pojedynczego palnika niskoemisyjnego stanowi istotny element syntezy układu sterowania, uwzględniającego informacje diagnostyczne, w tym te pochodzące z optycznego układu monitorowania płomienia. W celu opracowania modelu matematycznego procesu, realizowanego przy pomocy pojedynczego palnika niskoemisyjnego, pomiary przeprowadzono na stanowisku badawczym IEN. Eksperymenty obejmowały stabilizację punktu pracy stanowiska laboratoryjnego przy zróżnicowanych mocach, zróżnicowanych typach paliwa (uwzględniających węgiel oraz biomasę) oraz wymiennych trzech typach palników niskoemisyjnych. Pomiary zmiennych procesowych wykonywane były z częstotliwością 1Hz. Do zarejestrowanych wielkości należą wielopunktowe pomiary stężeń gazów spalin (NO_x, O₂, CO, CO₂), pomiary temperatur, ciśnień i przepływów oraz poziomy wysterowania wentylatorów powietrza. Pomiary optyczne, dotyczące płomienia, wykonane były z częstotliwością 1kHz.

Wstępny etap prac obejmował analizę wybranych, zarejestrowanych wielkości wejściowych i wyjściowych. Na potrzeby syntezy modeli wielowymiarowych (MIMO) określono wektory sygnałów wejściowych, opisujących ilościowo odpowiednio przepływ powietrza wtórnego, wydatek paliwa oraz wektory sygnałów wyjściowych obejmujących odpowiednio stężenia NO_x, CO oraz temperaturę w komorze. Dane podzielono na zbiory treningowe oraz testowe, stosując podział odpowiednio 70% i 30%. Korzystając z pakietu *System Identification Toolbox* przeprowadzono identyfikację parametrów dla modeli parametrycznych w przestrzeni stanu.

Badany obiekt potraktowano jako układ o strukturze szeregowej. Zatem wyjścia modeli na pierwszym poziomie stanowią wejścia dla modeli drugiego poziomu i opisują zależności pomiędzy stężeniami NO_x, CO, temperaturą w komorze oraz analogicznymi wielkościami w odpowiednim punkcie pomiarowym.


W celu przetestowania wiarygodności uzyskanych modeli, wykorzystując narzędzia z platformy Matlab/Simulink, zaprojektowano kontroler MPC. Pozwala on na wprowadzenie: ograniczeń na sygnały wyjściowe i sterujące, sygnałów zakłócających oraz horyzontów predykcji i sterowania. Zatem, umożliwia sprawdzenie modeli w kontekście ograniczeń normatywnych (np. co do emisji NO_x).

Widoczny na rysunku 4 diagram Simulink'a, z opracowanym modelem systemu sterowania procesem, uwzględnia możliwość modyfikacji zastosowanych modeli oraz projektowania regulatorów MPC.



Rys. 4. Diagram Simulink badanego układu sterowania

W ramach przeprowadzonych testów, uwzględniających ograniczenia co do norm emisji NO_x (300 ppm) najlepsze rezultaty w sensie NRMSE uzyskano dla modeli niskoemisyjnego palnika pierwszego (D1M1_4s6) oraz trzeciego (D3M1_4s3). Na rysunku 5 zamieszczono przykład analizy uzyskanych rezultatów, dla modeli P1 dla z danymi testowymi z procesu spalania.



Rys. 5. Porównanie odpowiedzi modeli P1 dla testowych danych z procesu spalania

W przypadku wybranych modeli (P2) spełnienie ograniczeń emisji było osiągnięte przy występujących oscylacjach (D2M1_4s5), a w przypadku (D2M1_4s6) – zakończone niepowodzeniem. Konfiguracja szeregowo przyniosła najlepsze rezultaty w połączeniu ze strukturami modeli (D2M2_4s4 oraz D2M2_4s10).

Sterowanie procesem współspalania z wykorzystaniem sygnałów optycznych z płomienia

Testy spalania zostały przeprowadzone na stanowisku badawczym IEN. Niskoemisyjny palnik NO_x zamontowany poziomo na przedniej ścianie komory o średnicy 0,1 m. Przygotowany wcześniej pył węglowy był składowany w bunkrze i dostarczany podajnikiem. W przypadku udziału biomasy, pył węglowy po przejściu przez podajnik był mieszany z biomasą, np. ze słomą.

Po obu stronach komory spalania znajdują się otwory inspekcyjne, pozwalające na obserwację przebiegu procesu spalania oraz zapewniające możliwość akwizycji danych. W ramach przeprowadzonych badań w pobliżu dyszy palnika umieszczono szybką kamerę z przetwornikiem CMOS. Kamera umożliwiła rejestrację obrazu o rozdzielczości 1280 x 1024 pikseli, z szybkością 500 klatek na sekundę. Do rejestracji obrazów płomienia wykorzystano boroskop o długości 0,7 m. Układ optyczny był chłodzony płaszczem wodnym, natomiast w celu uniknięcia zanieczyszczenia soczewek sondy zastosowano przedmuch oczyszczonym powietrzem. Zabieg ten, istotny z punktu widzenia rejestracji, wprowadza drobne zakłócenia w obszarze spalania w pobliżu palnika.

Przebieg eksperymentu wymagał odpowiedniego przygotowania, dlatego badanie było podzielone na kilka etapów. Wstępnie, komora spalania została rozgrzana z wykorzystaniem paliwa w postaci oleju. Po osiągnięciu odpowiedniego poziomu temperatury, wprowadzony został do palnika pył węglowy z powietrzem pierwotnym. Kolejna faza to wyłączenie palnika olejowego i wprowadzenie mieszanki węgla i biomasy. Współczynnik nadmiaru powietrza był określany przez przepływ powietrza wtórnego [5]. W trakcie prowadzonych badań założono dziewięć wariantów, w których moc cieplną (P_{th}) i współczynnik nadmiaru powietrza (λ) ustalano niezależnie dla znanej zawartości biomasy. Należy zauważyć, że λ zdefiniowano jako iloraz masy powietrza do spalania 1 kg paliwa do masy powietrza stechiometrycznego.

Pomiary zostały zrealizowane dla trzech wartości mocy cieplnej (250 kW, 300 kW i 400 kW) na wyjściu obiektu i określonych wartości współczynnika nadmiaru powietrza λ , równych odpowiednio 0,65, 0,75 i 0,85. Ponadto, testy obejmowały dwie mieszanki paliwowe zawierające 10% oraz 20% biomasy (w postaci słomy). W badaniach przyjęto za stałe parametry właściwości fizycznych biomasy (np. rozmiar cząstek, naturalna wilgotność itd.), jak również wszystkie parametry akwizycji obrazów (takie jak liczba klatek na sekundę i czas ekspozycji).

Dla przeprowadzonych pomiarów podjęto próbę określenia parametrów optycznych płomienia możliwych do użycia podczas diagnostyki oraz sterowania procesem spalania. Przyjęto założenie, że ze względu na potrzebę opracowania algorytmu sterowania online, obrazy z kamery przekształcono przez konwersję do 8-bitowej skali szarości. Obszar płomienia w każdej ramce uzyskanej sekwencji, został określony na podstawie amplitudy pikseli, aby odróżnić płomień względem innych zarejestrowanych obiektów w polu widzenia boroskopu. Zatem, suma wszystkich jasnych pikseli w analizowanym płomieniu

wyznaczała jego obszar. Współrzędne centrum pola płomienia (x, y) obliczano jako wartość średnią odpowiednio współrzędnych linii lub kolumn wszystkich pikseli z obszaru płomienia. Długość konturu płomienia została zdefiniowana jako suma wszystkich pikseli obwiedni, przy założeniu, że odległość między dwoma sąsiednimi punktami konturu równoległymi do osi współrzędnych ma wartość 1.

W proponowanym rozwiązaniu klasyczne podejście jest uzupełniane informacją o płomieniu na podstawie wybranych parametrów obrazu, zarejestrowanych szybko kamerą.

W rezultacie analizy, uwidocznił się związek pomiędzy parametrami opisującymi zmiany obrazu płomienia i temperatura gazów oraz ilością powietrza wtórnego. Powietrze pierwotne służy głównie do dostarczania pyłu węglowego do dyszy palnika, natomiast powietrze wtórne służy do zmian warunków procesu spalania (odstępstwo od stechiometrii). Parametry wejściowe, takie jak ilość paliwa w postaci mieszaniny węgla-biomasa i przepływów powietrza, były kilkakrotnie zmieniane podczas testów w celu utworzenia różnych stanów procesu spalania.


W przypadku niepełnej wiedzy o kontrolowanym obiekcie lub jego szybkich zmian w działaniu, kontrola adaptacyjna wydaje się rozsądnym podejściem.

Nieliniowa autoregresyjna sieć z wejściami egzogennymi (NARX) jest siecią dynamiczną, z połączeniami zwrotnymi obejmującymi kilka jej warstw. Model NARX oparty jest na liniowym modelu ARX, który jest powszechnie stosowany w modelowaniu szeregów czasowych. W równaniu modelu NARX, każda kolejna wartość zależnego sygnału wyjściowego wyznaczana względem poprzednich wartości wektora sygnału wyjściowego i poprzednich wartości niezależnego (egzogennego) sygnału wejściowego. Model NARX można zaimplementować za pomocą sieci neuronowej wprzód (ang. *feedforward*) w celu przybliżenia określonej funkcji. Taka implementacja pozwala również na wektorowy model ARX, w którym dane wejściowe i wyjściowe mogą być wielowymiarowe. Dane wyjściowe sieci NARX można uznać za oszacowanie wyników modelowanego nieliniowego systemu dynamicznego, które są przekazywane do wejścia sieci neuronowej za pomocą sprzężenia zwrotnego w ramach standardowej architektury NARX. W związku z faktem, że wynik jest dostępny podczas uczenia sieci, możliwe jest stworzenie architektury szeregowo-równoległej (patrz [7]), w której używane jest wyjście rzeczywiste zamiast szacunkowego wyniku. Niestandardową architekturą używaną do dalszych analiz jest algorytm sterowania adaptacyjnego (MRAC). Taka architektura sterowania ma dwie podsieci. Jedna podsieć to model kontrolowanej instalacji, a druga podsieć – to kontroler.

Wytrenowany model NARX, może być użyty do utworzenia całego systemu MRAC i włączenia go do wnętrza struktury regulatora w układzie. Aby system MRAC z zamkniętą pętlą odpowiadał w taki sam sposób, jak model referencyjny (wykorzystywany do generowania danych), wagi z wytrenowanej sieci powinny zostać umieszczone w systemie MRAC. Uczenie systemu MRAC trwało znacznie dłużej niż trening modelu NARX w związku z faktem, że w sieci zastosowano dynamiczną propagację wsteczną. Po nauczeniu sieci MRAC, przetestowano ją, z użyciem danych testowych.

Zaprojektowano i porównano dwa układy MRAC. Pierwszy z nich wykorzystywał oparty na pomiarach procesu klasyczny zbiór wektorów wejściowych, który odpowiednio ilościowo opisuje przepływ powietrza wtórnego, ilość paliwa i wektory opisujące odpowiednio temperaturę powietrza w komorze, zapisane w pierwszym punkcie pomiarowym. Drugi schemat wykorzystywał sygnał sterowania przepływem powietrza wtórnego, a wybrane deskryptory obszaru płomienia zostały wyznaczone w oparciu o metodę Otsu i długość konturu.

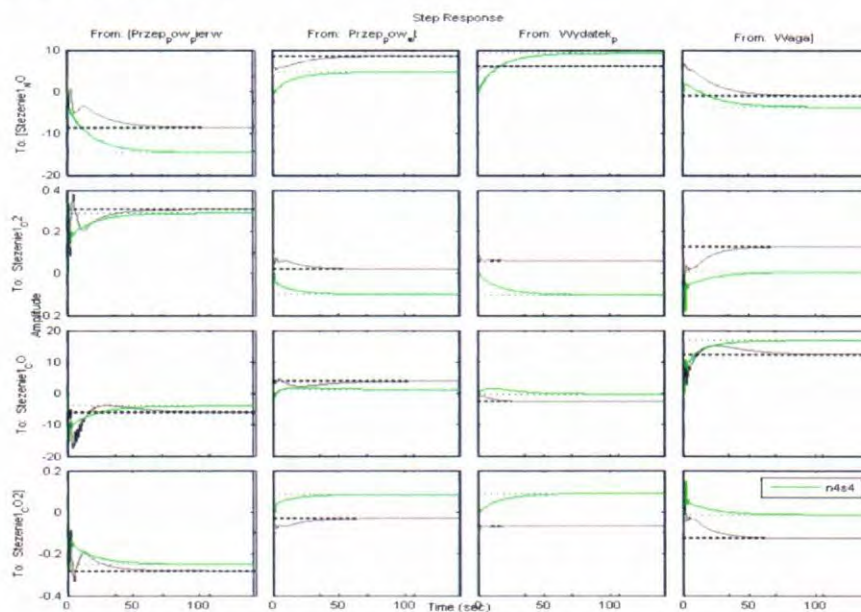
Na rysunku 6 przedstawiono reakcję systemu na wejściową wartość zadaną układu w obu przypadkach: z klasycznymi pomiarami (a) i po zastosowaniu pomiarów optycznych w postaci wektora długości konturu dla deskryptora płomienia (b). Wyniki symulacji pokazane na rysunku 6 świadczą o tym, że wyjście opracowanego modelu podąża za wejściem referencyjnym z poprawną, tłumioną odpowiedzią, nawet jeśli sekwencja wejściowa nie była taka sama jak sekwencja wejściowa w danych treningowych. Reakcja w stanie ustalonym może mieć przebieg oscylacyjny na każdym etapie, ale można to poprawić, stosując większy zestaw treningowy i być może więcej neuronów warstwie ukrytej. Z otrzymanych wyników zaproponowanego adaptacyjnego algorytmu sterowania można wywnioskować, że ograniczenia nałożone na wartości sygnałów sterowania, zapewniają stabilizację przebiegu procesu. Niemniej jednak będą one stanowić dla niego ograniczenie, wówczas, nagłe zmiany parametrów systemu będą wymagały gwałtownych reakcji układu sterowania.



Rys. 6. Odpowiedź układu sterowania kotłem pyłowym wykorzystującego (a) wektor danych wejściowych (b) dane wejściowe rozszerzoną o informację optyczną

Jak wspomniano wcześniej, nakładanie ograniczeń może być sposobem na zagwarantowanie stabilności. Analizowany system sterowania został poddany gwałtownej skokowej zmianie obciążenia. Ilustruje to krytyczną sytuację, która może

wystąpić w przypadku nieoczekiwanej zmiany parametrów układu. Uzyskane rezultaty przedstawiono na rysunku 7.



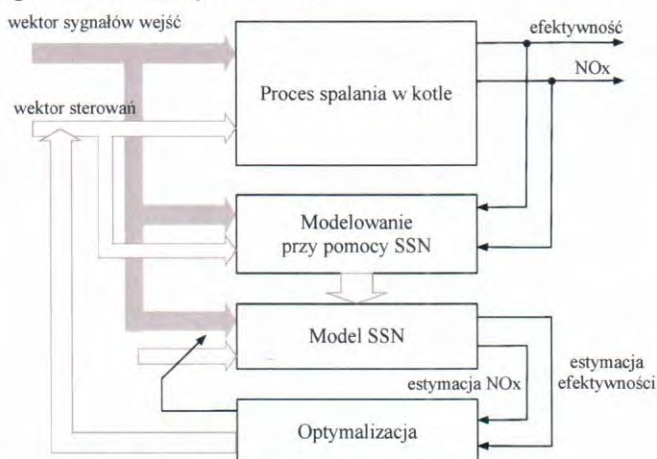
Rys. 7. Odpowiedź kontrolera MIMO na nagłą zmianę obciążenia mocy w odniesieniu stężeń NO_x, CO i temperatury spalin w komorze spalania.

Algorytm uwzględnił wszystkie nałożone ograniczenia, zarówno na sygnały sterowania, jak i wyjściowe. Potwierdza to jego odporność, a tym samym możliwości implementacji w układach rzeczywistych.

Modelowanie procesu metodami sztucznej inteligencji

Kolejne zagadnienie, poruszone w monografii dotyczy sterowania kotłem pyłowym z wykorzystaniem asymetrycznych sztucznych sieci neuronowych.

Efektywność spalania w kotłach i emisja NO_x są zwykle wybierane jako główne parametry funkcji celu w sterowania z modelem SSN. Model neuronowy umożliwia odwzorowanie zależności pomiędzy parametrami sterowania i wyjściami dla różnych warunków pracy, dzięki temu algorytm sterowania może zostać wykorzystany w roli systemu doradczego dla operatora lub bezpośrednio w sterowaniu procesem spalania w kotle. Schemat blokowy takiego rozwiązania pokazano na rysunku 8.



Rys. 8. Struktura typowego układu sterowania kotłem, z wykorzystaniem sztucznych sieci neuronowych