

POLITECHNIKA WARSZAWSKA

Wydział Elektroniki i Techniki  
Informacyjnych

ROZPRAWA DOKTORSKA

mgr inż. Konrad Wojdan

System optymalizacji bieżącej punktu pracy procesów  
technologicznych inspirowany działaniem układu  
immunologicznego

Promotor  
prof. dr hab. inż. Piotr Tatjewski

25 października 2008



# Streszczenie

W pracy zaprezentowano podstawy teoretyczne i realizację praktyczną systemu SILO realizującego bieżącą optymalizację punktu pracy procesów technologicznych. Algorytmy wykorzystywane w systemie SILO inspirowane są działaniem układu odpornościowego organizmów żywych. W pracy zaprezentowano warstwowy algorytm optymalizacji umożliwiający dostosowanie strategii wyznaczania optymalnego przyrostu sterowań nie tylko do aktualnego stanu procesu, ale również do wiedzy jaką system SILO posiada o procesie. Przedstawiono również algorytm odpowiedzialny za naukę procesu. W niniejszej rozprawie omówiono przykłady praktycznego wykorzystania Sztucznych Systemów Immunologicznych oraz zaprezentowano liniowe i nieliniowe algorytmy regulacji predykcyjnej z przesuwającym horyzontem. Wykazano, że dla pewnej klasy procesów technologicznych system SILO stanowi skuteczną alternatywę dla regulatorów MPC, ze względu na efektywny mechanizm zdobywania wiedzy i adaptacji do niestacjonarnych charakterystyk procesu oraz brak konieczności przeprowadzania czasochłonnych eksperymentów identyfikacyjnych i budowy modelu obiektu regulacji. Przedstawiona w niniejszej rozprawie analiza wdrożeń systemu SILO w elektrowniach zawodowych na dwóch blokach energetycznych w Polsce i dwóch blokach energetycznych w USA stanowi potwierdzenie skuteczności prezentowanego rozwiązania.



# Abstract

## **System of optimizing steady-state control of technical processes inspired by operation of an immune system**

In this PhD thesis theoretical foundations and practical implementation of a SILO system is presented. This system performs on-line optimizing steady-state control of industrial process. Algorithms implemented in this solution are inspired by operation of immune system of live creatures. An algorithm which chooses the best strategy of optimal control vector computation depending on current process state and SILO's knowledge is presented. Moreover, an operation of learning module, which is responsible for gathering knowledge about the process is also described. In this thesis utilization of Artificial Immune Systems is discussed. Moreover, linear and non-linear predictive control methods with receding horizon are also presented. It is shown that for particular class of industrial processes SILO system is a low-cost alternative for MPC controllers. It results from an immune inspired mechanism of knowledge gathering and effective adaptation to non-stationary process characteristics. Moreover, in SILO system there is no need to perform labor consuming identification experiments and there is no need to create *a priori* process model. Analysis of SILO implementation in large-scale power plants, in two power units in Poland and two power units in USA, confirms that presented solution is able to improve control quality in nominal plant conditions.



# Oznaczenia

## Spis akronimów

- SILO – Stochastic Immune Layer Optimizer,
- MPC – Model Predictive Control,
- PID – Proportional-Integral-Derivative controller,
- DMC – Dynamic Matrix Control,
- GPC – Generalized Predictive Control,
- SSTO – Stady-state Target Optimization,
- SCADA – Supervisory Control and Data Acquisition,
- DCS – Distributed Control System,
- PEPO – metoda Powtarzanych Estymacji Parametrów i Optymalizacji,
- PMO – metoda Powtarzanej Modyfikowanej Optymalizacji,
- ISOPE – Integrated System Optimization and Parametric Estimation,
- DPMO – dualny algorytm PMO,
- OFA – Over Fire Air,
- CCOFA – Close Coupled Over Fire Air,
- SOFA – Separated Over Fire Air,
- $\text{NO}_x$  – tlenki azotu,

---

CO – tlenek węgla,

MIMO – Multi Input Multi Output.

### Spis oznaczeń

$x$  – wektor wejść sterowanych,

$y$  – wektor wyjść obiektu regulacji,

$z$  – wektor mierzonych zakłóceń,

$d$  – wektor niemierzalnych i nieuwzględnianych zakłóceń,

$J(\cdot)$  – wskaźnik jakości,

$A$  – aktualny stan procesu definiowany jako trójka  $A = [x^a, y^a, z^a]$ ,

$x^a$  – wektor aktualnych sterowań,

$y^a$  – wektor aktualnych wartości wyjść procesu,

$z^a$  – wektor aktualnych wartości zakłóceń mierzonych,

$L_k$  –  $k$ -ty limfocyt typu B,

$M$  – okno czasowe limfocytu typu B,

$\mu(L_k, A)$  – funkcja stopnia powinowadztwa  $k$ -tego limfocytu B i antygeny  $A$ ,

$(\cdot)_+$  – operator opisany równaniem  $(x)_+ = \frac{1}{2}(x + |x|)$ ,

$K$  – macierz wzmocnień,

$M$  – macierz modelu bezpiecznego,

$cond(W)$  – stopień uwarunkowania macierzy  $W$ .



# Spis treści

<b>1</b>	<b>Wprowadzenie</b>	<b>11</b>
1.1	Układ rozprawy . . . . .	19
1.2	Teza rozprawy . . . . .	21
<b>2</b>	<b>Metody nadrzędnej regulacji i optymalizacji procesów</b>	<b>23</b>
2.1	Algorytm regulacji MPC . . . . .	24
2.1.1	Ogólna koncepcja regulacji predykcyjnej . . . . .	25
2.1.2	Realizacje algorytmów regulacji predykcyjnej . . . . .	27
2.1.3	Algorytmy regulacji predykcyjnej dla obiektów nieliniowych . . . . .	27
2.1.4	Sposoby uwzględnienia niedokładności modelu . . . . .	29
2.1.5	Regulator MPC w warstwowej strukturze sterowania . . . . .	30
2.1.6	Niepożądane właściwości podejścia MPC . . . . .	33
2.2	Metody optymalizacji punktu pracy . . . . .	36
<b>3</b>	<b>Sztuczne Systemy Immunologiczne</b>	<b>40</b>
3.1	Układ odpornościowy żywych organizmów . . . . .	40
3.2	Zastosowania teorii Sztucznych Systemów Immunologicznych . . . . .	43
<b>4</b>	<b>Implementacja systemu SILO w warstwowym układzie regulacji</b>	<b>47</b>
<b>5</b>	<b>Immunologiczna struktura systemu SILO</b>	<b>59</b>
5.1	Patogen . . . . .	59
5.2	Limfocyt typu B i $T_h$ . . . . .	62
5.3	Przeciwciało . . . . .	66
5.4	Układ dopełniacza . . . . .	69
<b>6</b>	<b>Ogólna zasada działania</b>	<b>71</b>
<b>7</b>	<b>Moduł uczenia</b>	<b>76</b>

<b>8</b>	<b>Moduł optymalizacji</b>	<b>93</b>
8.1	Warstwa optymalizacji na modelu mieszanym . . . . .	98
8.2	Warstwa optymalizacji na modelu globalnym . . . . .	114
8.3	Warstwa optymalizacji stochastycznej . . . . .	115
8.4	Algorytm przełączania między warstwami . . . . .	119
8.5	Stabilność i niezawodność . . . . .	124
<b>9</b>	<b>Porównanie właściwości systemu SILO i regulacji predykcyjnej</b>	<b>126</b>
9.1	Wdrożenie systemu optymalizacji . . . . .	126
9.2	Porównanie postaci modelu i wskaźnika jakości, oraz innych właściwo- ści obu rozwiązań . . . . .	132
<b>10</b>	<b>Proces spalania w kotle energetycznym</b>	<b>136</b>
10.1	Proces technologiczny elektrowni . . . . .	136
10.2	Kocioł energetyczny jako obiekt regulacji . . . . .	142
<b>11</b>	<b>Wyniki i analiza wdrożeń systemu SILO</b>	<b>147</b>
11.1	Wdrożenie systemu SILO w jednej z amerykańskich elektrowni . . . . .	147
11.1.1	Wdrożenie SILO na bloku pierwszym . . . . .	152
11.1.2	Wdrożenie SILO na bloku drugim . . . . .	163
11.2	Wdrożenie systemu SILO w jednej z polskich elektrowni . . . . .	169
11.2.1	Wyniki osiągnięte przez system SILO na bloku nr. 1 . . . . .	174
11.2.2	Wyniki osiągnięte przez system SILO na bloku nr. 2 . . . . .	179
11.3	Ogólne wnioski z przeprowadzonych wdrożeń . . . . .	186
<b>12</b>	<b>Podsumowanie</b>	<b>188</b>
<b>A</b>	<b>Wkład osób trzecich w rozwój systemu SILO</b>	<b>192</b>
<b>B</b>	<b>Zakończone i planowane wdrożenia systemu SILO</b>	<b>193</b>
<b>C</b>	<b>Otrzymane wyróżnienia</b>	<b>194</b>

# Rozdział 1 Wprowadzenie

Temat regulacji i optymalizacji bieżącej punktu pracy procesów technologicznych był wielokrotnie podejmowany w licznych pracach naukowych i wdrożeniowych [99, 86, 87, 67, 74, 82, 83]. Duże zainteresowanie instytucji naukowych i firm badawczych tego typu zagadnieniami wynika z tego, że udane wdrożenie rozwiązań z zakresu automatyki zaawansowanej i optymalizacji procesów technologicznych pozwalana na osiągnięcie znacznych korzyści ekonomicznych przez zakłady przemysłowe, oraz na zmniejszenie negatywnego wpływu tych zakładów na środowisko naturalne.

Procesy technologiczne zachodzące w obiektach dużej skali, o wysokim stopniu złożoności, charakteryzują się znaczną liczbą wejść sterowanych i zakłóceń, długimi czasami odpowiedzi wyjść obiektu na zmianę sterowania, istotnie nieliniowymi charakterystykami oraz trudnymi do pominięcia transmitancjami skrośnymi. Klasyczne układy regulacji oparte w głównej mierze na regulatorach PID nie są w sposób optymalny sterować tego typu procesami. Głównym celem klasycznego układu sterowania jest zapewnienie niezawodności pracy i bezpieczeństwa procesu. Optymalizacja procesów technologicznych powinna uwzględniać:

- wielość celów optymalizacji (często sprzecznych ze sobą),
- dużą liczbę zmiennych sterujących,
- ograniczenia zadania optymalizacji,
- mierzone, rzadko mierzone i niemierzalne zakłócenia oddziałujące na proces,
- wewnętrzne (w ogólności nieliniowe) zależności istniejące między wejściami i wyjściami obiektu.

Tak więc wyraźnie widać konieczność wprowadzenia dodatkowych warstw sterowania realizujących zadanie optymalizacji i/lub regulacji zaawansowanej, które to warstwy będą nadrzędne w stosunku do klasycznego układu regulacji.

Najbardziej rozpowszechnionymi w zastosowaniach przemysłowych rozwiązaniami realizującymi zaawansowaną regulację procesów przemysłowych są metody oparte na algorytmie regulacji predykcyjnej z przesuwającym horyzontem [99, 64]. Historia algorytmów MPC sięga końca lat siedemdziesiątych ubiegłego wieku [84, 22]. Ich wprowadzenie miało kolosalny wpływ na rozwój dziedziny sterowania procesami technologicznymi. Liczne udane wdrożenia algorytmów predykcyjnych w różnych gałęziach przemysłu sprawiły, że regulatory MPC zyskały sobie zasłużone zaufanie klientów przemysłowych, oraz przyciągnęły uwagę środowiska naukowego, dzięki któremu regulacja predykcyjna to żywa, ciągle rozwijana dziedzina.

Regulator MPC wykorzystując wiedzę o procesie zawartą w modelu dynamicznym, wyznacza wartości elementów wektora sterowań w kolejnych chwilach czasu  $x(k)$ ,  $x(k+1)$ , ...,  $x(k+N_u-1)$ , w taki sposób, aby zminimalizować różnicę między estymowanymi na podstawie modelu i zadanymi wartościami wyjść obiektu w kolejnych chwilach czasu. Istnieją różne realizacje algorytmów regulacji predykcyjnej z przesuwającym horyzontem, takie jak DMC (ang. Dynamic Matrix Control) [22, 35], GPC (ang. Generalized Predictive Control) [21, 13] czy rozwiązania wykorzystujące model w postaci równań stanu [64]. Przedstawione rozwiązania różnią się głównie postacią wykorzystywanego dynamicznego, liniowego modelu obiektu regulacji. Główna koncepcja, polegająca na wyznaczaniu w każdej iteracji algorytmu trajektorii sterowania na horyzoncie sterowania, minimalizującej wskaźnik jakości uwzględniający między innymi różnicę między przyszłymi wartościami zadanymi i estymowanymi wyjść obiektu na horyzoncie predykcji, stanowi wspólny mianownik wszystkich algorytmów regulacji predykcyjnej.

Stopień nieliniowości charakterystyk procesów technologicznych jest czasami na tyle duży, że niemożliwe jest uzyskanie dobrych wyników przy użyciu metod bazujących na modelach liniowych. Nieliniowości te muszą być uwzględnione przez metody regulacji predykcyjnej [69, 70]. Najbardziej rozpowszechnionym podejściem w zastosowaniu do zaawansowanej regulacji procesów przemysłowych jest wykorzystanie teorii logiki rozmytej do stworzenia quasi-liniowego regulatora MPC [73, 96, 31, 81]. Takie podejście skutkuje tym, że inżynier wdrażający regulator musi zbudować liniowe modele obiektu dla obszarów pracy, w których liniowa aproksymacja jest wystarczająco dokładna, a następnie dokonać rozmycia tych modeli (lub regulatorów - patrz rozdział 2) w oparciu o zdefiniowany wcześniej podział na partycje rozmyte.

Znanych jest wiele udanych wdrożeń regulacji predykcyjnej do sterowania procesami technologicznymi [85, 27, 86]. Pomimo niewątpliwych zalet regulatorów MPC istnieje kilka poważnych mankamentów tego typu rozwiązań. Po pierwsze wdrożenie regulatora MPC jest stosunkowo kosztowne. Aby zbudować liniowy, dynamiczny model procesu należy wykonać szereg długotrwałych i pracochłonnych testów parametrycznych obiektu regulacji. Eksperymenty przeprowadzane są w taki sposób, że na jedno ze sterowanych wejść obiektu wprowadza się wymuszenie skokowe i rejestruje się odpowiedź obiektu na to wymuszenie. Podczas takiego testu musi być spełniony warunek, że zakłócenia oddziałujące na proces, oraz pozostałe wejścia sterowane utrzymywane są na stałym poziomie. Następnie pojedynczy test powtarzany jest dla kolejnych zmiennych sterujących. Aby zapewnić dobrą jakość modeli, testy powtarzane są kilkakrotnie dla jednej zmiennej sterującej. Dane z tych testów wykorzystywane są do identyfikacji modelu. Chcąc uwzględnić nieliniowość obiektu, stosując modelowanie rozmyte typu Takagi-Sugeno, należy zbudować po jednym modelu dla każdej partycji rozmytej. Wydłuża to ilość koniecznych do przeprowadzenia testów i ogranicza możliwość stworzenia większej ilości partycji rozmytych, co przekłada się na mniej dokładną aproksymację nieliniowej charakterystyki procesu. Należy również pamiętać, że wysoki koszt wdrożenia w głównej mierze wynika z wysokiego kosztu pracy wykwalifikowanego inżyniera przeprowadzającego testy obiektu i identyfikującego dynamiczny model obiektu. Ponadto długotrwałe testy wymagają zapewnienia określonych warunków pracy obiektu, narzuconych przez zespół wdrażający regulator. Warunki te są często sprzeczne z planem produkcji zakładu przemysłowego, wynikającym z konieczności dotrzymania zobowiązań kontraktowych. Należy również mieć na uwadze, że podczas testów obiekt często pracuje w sposób nieefektywny, co przekłada się na straty finansowe zakładu przemysłowego. Istnieją także obiekty, w których nie możliwe jest przeprowadzenie testów we wszystkich konfiguracjach pracy obiektu. Wynika to na przykład ze zbyt dużej liczby zmiennych sterujących, awarii urządzeń wykonawczych lub ograniczeń narzuconych przez zakład przemysłowy, wynikających z konieczności zapewnienia bezpieczeństwa pracy obiektu i przesłanek ekonomicznych. Firma Honeywell obliczyła, że koszt budowy dynamicznego modelu obiektu wynosi od 250 USD do 1000 USD dla każdej pojedynczej zależności między wejściem i wyjściem obiektu [27]. W przypadku optymalizacji obiektu składającego się z dziesięciu wejść sterowanych, pięciu wejść niesterowanych i czterech wyjść

(średni wymiar zadania optymalizacji procesu spalania zachodzącego w kotle energetycznym) koszt stworzenia jednego modelu w.g. obliczeń ekspertów z firmy Honeywell waha się od 15000 USD do 60000 USD. Kwota ta obejmuje zaprojektowanie eksperymentów identyfikacyjnych, przeprowadzenie testów obiektu, identyfikację i walidację modelu. Koszt ten nie uwzględnia jednak ceny oprogramowania, sprzętu i kosztów związanych ze szkoleniem kadry inżynierskiej. Nie uwzględnione są również straty finansowe poniesione przez zakład przemysłowy w trakcie trwania testów, wynikające z nieefektywnego prowadzenia procesu.

Kolejnym mankamentem regulacji predykcyjnej są trudności w uwzględnieniu ciągłych zmian charakterystyk procesu. Zmiany te, rozpatrywane na horyzoncie miesięcy i lat, wynikają ze zużycia i awarii urządzeń wykonawczych, zmiany sposobu prowadzenia procesu, przebudowy instalacji przemysłowej, istotnych zmian właściwości chemicznych używanych składników (np.: decyzja o dodawaniu domieszki biomasy do paliwa dostarczanego do kotła energetycznego) oraz zmiany warunków zewnętrznych (uwzględnienie sezonowości). Najprostszym sposobem na uwzględnienie tych zmian jest okresowe dostrajanie modeli, na podstawie nowych testów identyfikacyjnych obiektu regulacji. Nie stanowi to jednak satysfakcjonującego rozwiązania tego problemu. Bardziej pożądanym rozwiązaniem jest zaimplementowanie mechanizmów adaptacji w regulatorze MPC. Z podejściem tym związanych jest szereg problemów:

- wyznaczenie parametrów modelu przy niewystarczającej zmienności sygnałów, w obecności szumów pomiarowych [59],
- wyznaczenie parametrów modelu podczas pracy w zamkniętej pętli sprzężenia zwrotnego [46, 92],
- stosunkowo duży nakład mocy obliczeniowych potrzebny podczas pracy w trybie on-line,
- możliwość wystąpienia liniowych zależności w macierzy obserwacji, zbudowanej z pomiarów wartości sygnałów procesowych wykorzystywanych do adaptacji modelu.

Przedstawione problemy sprawiają, że mechanizmy adaptacji zaimplementowane w regulatorach MPC w zastosowaniu do sterowania procesami technologicznymi często nie spełniają pokładanych w nich nadziei. Z doświadczeń firmy Transition Technologies S.A.<sup>1</sup> wynika, że w przypadku zastosowania regulatora MPC do optymalizacji

---

<sup>1</sup> Firma Transition Technologies S.A. ([www.tt.com.pl](http://www.tt.com.pl)) to polska firma dostarczająca rozwiązań m.in. z

procesu spalania w kotle energetycznym konieczność ponownego dostrojenia modeli występuje średnio już po ok. dwóch latach od zakończenia pierwszego wdrożenia. Czas ten zależy od stopnia skomplikowania zadania optymalizacji oraz od innych czynników związanych z konkretnym obiektem regulacji.

Powyższe mankamenty regulatorów MPC skłaniają do poszukiwania nowych rozwiązań. Często inspiracją w takich poszukiwaniach okazuje się obserwacja mechanizmów i zależności występujących w świecie żywych organizmów. Metody bazujące na biologicznych obserwacjach takie jak: Sztuczne Sieci Neuronowe (ang. Artificial Neural Networks) [76, 39, 95, 78], Algorytmy Ewolucyjne (ang. Evolutionary Algorithms) [2, 7], Algorytmy Mrówkowe (ang. Ant Colony Optimization) [30, 1] czy Optymalizacja Rojem Cząstek (ang. Swarm Optimization) [8, 50] znalazły szerokie zastosowanie przy rozwiązywaniu wielu skomplikowanych problemów technicznych. Znane są również metody wykorzystania tych rozwiązań do optymalizacji procesów technologicznych. Firma Transition Technologies S.A. wielokrotnie wdrażała regulatory MPC z hybrydowym modelem procesu, wykorzystującym m.in. Sztuczną Sieć Neuronową [4, 112, 28, 120]. Firma Pegasus w swoich regulatorach predykcyjnych również stosowała Sztuczną Sieć Neuronową do modelowania procesu, a algorytm ewolucyjny służył do znalezienia optymalnej trajektorii sterowań [79]. Poszukując rozwiązania pozbawionego wspomnianych mankamentów regulatorów MPC, umożliwiającego bieżącą (realizowaną w czasie rzeczywistym) optymalizację procesu przemysłowego, warto zwrócić uwagę na młodą, dynamicznie rozwijającą się dziedzinę nauki jaką są Sztuczne Systemy Immunologiczne (ang. Artificial Immune Systems) [17, 18, 110]. Ten nowy nurt inspirowanych biologią rozwiązań bazuje na obserwacji działania układu odpornościowego organizmów żywych. Układ odpornościowy to szczególnie układ organizmu, posiadający pamięć i podnoszący swoje umiejętności poprzez naukę i doświadczenie. W zależności od warunków układ ten jest w stanie rozwinąć nowe umiejętności, ale również może utracić już posiadane zdolności. Patrząc na układ odpornościowy z inżynierskiego punktu widzenia, jest to efektywny rozproszony system przetwarzania informacji. Posiada on zdolność do nauki, oraz potrafi adaptować się do zmieniających się warunków zewnętrznych. Należy zwrócić uwagę, że wspomniane właściwości układu odpornościowego są wielce przydatne w kontekście bieżącej optymalizacji procesów technologicznych.

---

zakresu zaawansowanej regulacji procesów technologicznych. Firma opracowała i wdrożyła regulatory predykcyjne na ponad 30 blokach energetycznych w Polsce, USA i Azji.

Istnieje wiele prac poświęconych teorii Sztucznych Systemów Immunologicznych [24]. Główne obszary zainteresowania tej dziedziny to: wykrywanie anomalii [94, 44], rozpoznawanie wzorców [15], eksploracja danych [104], bezpieczeństwo systemów informatycznych [53, 23, 41, 9], wykrywanie błędów [25, 12] i sterowanie adaptacyjne [58, 47]. Pomimo dużej ilości prac poświęconych Sztucznym Systemom Immunologicznym stosunkowo mało rozwiązań zostało wdrożonych w rzeczywistym świecie. Nie znane są autorowi wdrożenia metod inspirowanych działaniem układu odpornościowego w zastosowaniu do regulacji procesów technologicznych. Tylko jedno rozwiązanie z dziedziny sterowania, bazujące na teorii Sztucznych Systemów Immunologicznych doczekało się implementacji w przemyśle lotniczym [47]. Prace dotyczące wykorzystania mechanizmów układu odpornościowego do sterowania, w szczególności do sterowania adaptacyjnego, znajdują się w fazie rozważań teoretycznych i prac laboratoryjnych. Prace te dotyczą głównie:

- strojenia parametrów regulatorów PID [51],
- wyznaczania prawa sterowania w oparciu o mechanizmy regulujące koncentracje limfocytów  $T_s$  i  $T_h$  w układzie odpornościowym [20],
- wyznaczania prawa sterowania w oparciu o znany *a priori* i na bieżąco modyfikowany model matematyczny [47].

W trzeciej najmocniej rozwijanej klasie prac [57, 56, 58] zakłada się posiadanie *a priori* modelu matematycznego obiektu regulacji. Adaptacja odbywa się w oparciu o algorytm genetyczny, który wyznacza parametry modelu lub regulatora. Należy zwrócić uwagę na relatywnie wysoki koszt wdrożenia takiego rozwiązania. Zaproponowane podejście łączy w sobie konieczność posiadania *a priori* modelu obiektu, oraz konieczność zdefiniowania algorytmu ewolucyjnego, co czyni je jeszcze bardziej czasochłonnym w kontekście wdrożenia w porównaniu do regulatorów MPC. Zatem stworzenie metody optymalizacji procesu technologicznego, pozbawionej mankamentów regulatorów MPC, z wykorzystaniem podejścia zaproponowanego w [57, 47] jest niemożliwe.

W niniejszej rozprawie zaprezentowano system SILO (ang. Stochastic Immune Layer Optimizer) [115, 119, 114, 118, 117, 120] - nowatorskie rozwiązanie do bieżącej optymalizacji punktu pracy procesów technologicznych, bazujące na mechanizmach inspirowanych działaniem układu odpornościowego organizmów żywych. Jest



to pierwsze na świecie rozwiązanie, wykorzystujące mechanizmy układu odpornościowego, zastosowane do bieżącej optymalizacji procesów przemysłowych, w szczególności do bieżącej optymalizacji punktu pracy procesu spalania w kotle energetycznym. Podobnie jak w przypadku ekonomicznej optymalizacji punktu pracy [100], oraz w przypadku SSTO (ang. Stady-state Target Optimiztion) [100, 11, 49], SILO wykorzystuje wiedzę zawartą w modelu statycznym. W SILO zastosowano jednak regulacyjny wskaźnik jakości. Przedstawione w niniejszej rozprawie rozwiązanie, na podstawie wiedzy zgromadzonej w pamięci immunologicznej, minimalizuje różnicę między zadaną i zmierzoną (lub estymowaną) wartością wyjść obiektu. Rozwiązaniem zdania optymalizacji statycznej jest wektor sterowań, będący wektorem wartości zadanych dla regulatorów warstwy regulacji bezpośredniej na najbliższy okres czasu. Architektura systemu SILO pozwala jednak również na zdefiniowanie ekonomicznego wskaźnika jakości (patrz podrozdział 2.2), definiującego ekonomiczny cel produkcji (najczęściej zysk). Wówczas system SILO może być stosowany jako ekonomiczny optymalizator punktu pracy procesów technologicznych. Ze względu na główny obszar dotychczasowych wdrożeń prezentowanego systemu, jakim jest optymalizacja procesu spalania w kotle energetycznym, w pracy skoncentrowano się na przedstawieniu rozwiązania wykorzystującego regulacyjną postać wskaźnika jakości. Należy jednak pamiętać, że definiując regulacyjny wskaźnik jakości bierze się pod uwagę przesłanki ekonomiczne.

Przeprowadzone przez autora, we współpracy z firmą Transition Technologies S.A. i Emerson Process Management, wdrożenia prezentowanego rozwiązania na czterech blokach energetycznych w Polsce i pięciu blokach energetycznych w USA stanowią pierwsze na świecie wdrożenia Sztucznego Systemu Immunologicznego do optymalizacji procesu technologicznego, w szczególności do optymalizacji procesu spalania w kotle energetycznym dużej skali. System SILO jest nowatorskim pomysłem w dziedzinie optymalizacji punktu pracy procesów przemysłowych, ale stanowi także oryginalny wkład w teorię Sztucznych Systemów Immunologicznych. Pomimo pewnych nieuniknionych podobieństw do innych metod czerpiących inspirację z działania układu odpornościowego organizmów żywych, system SILO posiada wiele oryginalnych, niepowtarzalnych rozwiązań, które mogą być wykorzystane przez osoby rozwijające tematykę Sztucznych Systemów Immunologicznych. Na tle dotychczasowych prac badawczych poświęconych wykorzystaniu mechanizmów układu odpornościowego w dziedzinie regulacji, system SILO wyróżnia się m.in.:

- brakiem konieczności posiadania *a priori* modelu obiektu regulacji,

- umiejętnością dostosowania strategii poszukiwania optymalnego rozwiązania do wiedzy zgromadzonej w pamięci immunologicznej (pierwotna i wtórna odpowiedź immunologiczna),
- wykorzystaniem informacji o sile wiązania antygen-przeciwciała, uwzględnianej podczas automatycznego doboru parametrów modelu obiektu w każdym kroku optymalizacji.

System SILO może być stosowany do regulacji takich procesów, w których zmiana zakłóceń następuje szybko, ale rzadko lub w których zakłócenia zmieniają się w sposób ciągły, ale prędkość tych zmian jest dużo wolniejsza od dynamiki regulowanego obiektu. W zakładach przemysłowych spełniających ten warunek, system SILO stanowi tanią w sensie ekonomicznym alternatywę dla regulatorów MPC. Wynika to z:

- Braku konieczności wykonywania parametrycznych testów obiektu. Należy pamiętać, że koszt pracy wykwalifikowanego inżyniera wdrażającego system regulacji zaawansowanej stanowi istotne obciążenie dla budżetu elektrowni. Ponadto testy powodują zazwyczaj nieefektywne prowadzenie procesu, co przekłada się na starty finansowe zakładu przemysłowego;
- Braku konieczności budowy modelu matematycznego obiektu regulacji na podstawie eksperymentów identyfikacyjnych. Fakt ten również oznacza istotną redukcję czasu pracy wykwalifikowanej kadry inżynierskiej;
- Możliwości uwzględnienia większej liczby stanów pracy obiektu regulacji. System SILO w sposób automatyczny uczy się optymalizowanego procesu i dokonuje adaptacji posiadanej wiedzy do aktualnego punktu pracy. W systemie SILO można wymusić większą dokładność aproksymacji statycznej charakterystyki procesu, poprzez zdefiniowanie węższych obszarów pracy i większej ilości sygnałów definiujących te obszary, w których aproksymacja procesu modelem liniowym jest wystarczająco dokładna. W przypadku regulatorów MPC ilość takich obszarów (partycji) była ograniczona przez nakład pracy związany z wykonaniem testów parametrycznych obiektu w każdym z tych obszarów;
- Inspirowanych działaniem układu odpornościowego efektywnych algorytmów zdobywania wiedzy o procesie i adaptacji do zmieniających się warunków pracy, stanowiących integralną część systemu SILO. Implementacja mechanizmów adaptacji

modelu dynamicznego w regulatorach MPC nie jest rzeczą łatwą. Mechanizmy te często nie spełniają pokładanych w nich nadziei. W dotychczasowych wdrożeniach systemu SILO nie wystąpiła konieczność ręcznego dostrojenia modelu obiektu, co więcej zauważa się wręcz poprawę jakości regulacji w ciągu pierwszych dwóch miesięcy od zakończenia wdrożenia.

System SILO stanowi oryginalne rozwiązanie autora. Osoby, które przyczyniły się do rozwoju tego systemu, oraz wkład tych osób w rozwój SILO został przedstawiony w załączniku A. Wyniki uzyskiwane przez system SILO w elektrowniach w Polsce i USA potwierdzają, że teoretyczne rozważania leżące u podstaw systemu SILO znajdują zastosowanie w rzeczywistości. Za wartości merytoryczne pracy uważa się:

- wykorzystanie mechanizmów inspirowanych działaniem układu odpornościowego organizmów żywych, do bieżącej optymalizacji punktu pracy procesu technologicznego;
- opracowanie warstwowego algorytmu optymalizacji, dostosowującego swoje działanie nie tylko do aktualnego stanu procesu, ale także do wiedzy jaką system SILO posiada na temat regulowanego obiektu;
- opracowanie metody zdobywania wiedzy o procesie i wykorzystania jej do tworzenia modeli matematycznych obiektu regulacji;
- porównanie właściwości systemu SILO z algorytmami regulacji predykcyjnej z przesuwany horyzontem;
- analizę wdrożeń przedstawionego rozwiązania na czterech rzeczywistych blokach energetycznych.

## 1.1 Układ rozprawy

W rozdziale drugim przedstawiono metody nadrzędnej regulacji procesów technologicznych oraz metody ekonomicznej optymalizacji punktu pracy procesów technologicznych. Metody te zostały przyporządkowane do odpowiednich warstw w warstwowej strukturze sterowania. Omówienie tych metod jest niezbędne w celu przedstawienia dotychczasowych rozwiązań realizujących nadrzędną regulację i optymalizację procesów technologicznych i porównania ich z systemem SILO. W szczególności nie

możliwe jest udowodnienie tezy roboczej 1.2.3, bez wcześniejszej analizy algorytmów regulacji predykcyjnej. W pierwszej części rozdziału drugiego przedstawiono ogólną koncepcję regulacji MPC, oraz omówiono podstawowe realizacje algorytmów bazujących na liniowym modelu obiektu. Następnie opisano rozwiązania umożliwiające uwzględnienie nieliniowości obiektu regulacji. W kolejnej części rozdziału przedstawiono niepożądane właściwości podejścia opartego na regulacji predykcyjnej, stanowiące bezpośredni przyczynek do stworzenia systemu SILO. W ostatniej części rozdziału drugiego omówiono metody ekonomicznej optymalizacji punktu pracy procesów technologicznych i porównano je z systemem SILO.

Algorytmy zaimplementowane w systemie SILO czerpią inspirację z działania układu odpornościowego organizmów żywych. W pierwszej części rozdziału trzeciego przedstawiono strukturę i działanie układu odpornościowego. W drugiej części rozdziału omówiono wykorzystanie Sztucznych Systemów Immunologicznych do rozwiązywania rzeczywistych problemów. Najwięcej miejsca poświęcono wykorzystaniu metod czerpiących inspirację z działania układu odpornościowego w dziedzinie regulacji.

W rozdziale czwartym przedstawiono sposób implementacji systemu SILO w warstwowej strukturze sterowania. Omówiono współdziałanie systemu SILO zaimplementowanego w warstwie regulacji nadrzędnej z warstwą regulacji bezpośredniej opartą na regulatorach PID.

W rozdziale piątym przedstawiono immunologiczną strukturę systemu SILO. Omówiono podobieństwa istniejące między układem odpornościowym i prezentowanym w niniejszej rozprawie rozwiązaniem.

W rozdziale szóstym omówiono wstępnie działanie systemu SILO. Przedstawiono funkcje poszczególnych modułów prezentowanego rozwiązania, oraz pokazano ich wzajemne współdziałanie.

Rozwinięciem rozważań przedstawionych w rozdziale szóstym jest rozdział siódmy i ósmy. W rozdziale siódmym w sposób szczegółowy omówiono działanie modułu odpowiedzialnego za zdobywanie wiedzy o obiekcie regulacji.

W rozdziale ósmym przedstawiono działanie modułu optymalizacji systemu SILO. Moduł ten wykorzystuje wiedzę na temat obiektu regulacji do wyznaczenia optymalnego przyrostu sterowań minimalizującego wartość wskaźnika jakości. Na początku tego rozdziału przedstawiono warstwową budowę algorytmu optymalizacji. Następnie

w sposób szczegółowy omówiono działanie każdej z warstw. Na zakończenie rozdziału opisano mechanizm odpowiedzialny za wybór poszczególnych warstw algorytmu optymalizacji.

W rozdziale dziewiątym porównano właściwości systemu SILO z właściwościami metod regulacji predykcyjnej. Porównano przebieg procesu wdrożenia obu rozwiązań na rzeczywistym obiekcie. Omówiono zastosowanie systemu SILO jako narzędzia do przeprowadzania w sposób automatyczny eksperymentów identyfikacyjnych na potrzeby budowy dynamicznych modeli obiektu wykorzystywanych przez regulatory predykcyjne. Porównano postać wskaźnika jakości i postać modelu wykorzystywanego przez regulator MPC i system SILO, oraz przeanalizowano wady i zalety obydwu rozwiązań w kontekście ich oceny przez kadrę nadzorującą proces i kadrę zarządzającą zakładem przemysłowym.

W rozdziale dziesiątym przedstawiono główne układy procesu technologicznego konwencjonalnej elektrowni parowej, szczególnie dużo miejsca poświęcając procesowi spalania. W drugiej części rozdziału przedstawiono kocioł energetyczny dużej skali jako nieliniowy obiekt regulacji posiadający wiele wejść i wiele wyjść.

W rozdziale jedenastym przeanalizowano wyniki wdrożeń systemu SILO na czterech blokach energetycznych. Wyniki te potwierdzają skuteczność przedstawionego w niniejszej rozprawie rozwiązania.

W ostatnim rozdziale podsumowano dotychczasowe rozważania.

## 1.2 Teza rozprawy

W rozdziale tym zostanie sformułowana teza główna i tezy robocze niniejszej rozprawy. Udowodnienie tych tez stanowi cel rozprawy.

**Teza główna 1.2.1** *System SILO, wykorzystujący mechanizmy inspirowane działaniem układu odpornościowego organizmów żywych, jest rozwiązaniem skutecznie realizującym w czasie rzeczywistym optymalizację punktu pracy pewnej klasy procesów technologicznych.*

**Teza robocza 1.2.2** *Wykorzystanie mechanizmów inspirowanych działaniem układu odpornościowego organizmów żywych pozwala na ciągłe zdobywanie wiedzy o optymalizowanym procesie i skuteczną adaptację do nowych warunków pracy.*

**Teza robocza 1.2.3** *Dla pewnej klasy procesów technologicznych, w szczególności dla procesu spalania w kotle energetycznym dużej skali, system SILO stanowi tanią w sensie ekonomicznym alternatywę dla regulatorów MPC, ze względu na:*

- *brak konieczności przeprowadzania czasochłonnych eksperymentów identyfikacyjnych obiektu regulacji, potrzebnych do budowy modelu obiektu regulacji wykorzystywanego przez algorytm MPC;*
- *brak konieczności budowy na podstawie wyników eksperymentów identyfikacyjnych matematycznego modelu wykorzystywanego przez algorytm MPC;*
- *brak konieczności ręcznego dostrajania parametrów modelu matematycznego reprezentującego obiekt regulacji, po wystąpieniu istotnych zmianach charakterystyk optymalizowanego procesu.*

**Teza robocza 1.2.4** *Moduł optymalizacji, składający się z trzech przełączanych między sobą algorytmów, pozwala na skuteczną realizację celów optymalizacji, w zależności od posiadanej przez system SILO wiedzy o procesie.*


Tezy 1.2.1 i 1.2.3 wymagają komentarza. Przez *szczególną klasę procesów* rozumie się takie procesy, w których zmiana zakłóceń następuje szybko, ale rzadko lub zakłócenia zmieniają się w sposób ciągły, ale prędkość tych zmian jest dużo wolniejsza od dynamiki obiektu regulowanego. Innymi słowy można powiedzieć, że przez *szczególną klasę procesów* rozumie się takie procesy w których istotne zakłócenia utrzymują się na pewnym stałym poziomie (z dokładnością do pewnego przedziału, w którym zawiera się szum pomiarowy i oscylacje o zerowej wartości oczekiwanej) przez czas nie krótszy niż czas potrzebny na ustalenie się optymalizowanych wyjść procesu na pewnym stałym poziomie (z dokładnością do pewnego przedziału, w którym zawiera się szum pomiarowy i oscylacja o zerowej wartości oczekiwanej) po wystąpieniu zmiany sygnałów sterujących.

Udowodnienie tezy roboczej 1.2.4 polegać będzie na wykazaniu skuteczności warstwowego algorytmu optymalizacji, realizującego eksploatację i eksplorację przestrzeni rozwiązań. W zależności od posiadanej przez system SILO wiedzy o procesie, algorytm optymalizacji kładzie większy nacisk na eksplorację lub eksploatację przestrzeni rozwiązań. Stochastyczna eksploracja przestrzeni rozwiązań odpowiada pierwotnej odpowiedzi immunologicznej (patrz rozdział 3). Algorytm realizujący eksploatację bazuje na wiedzy zgromadzonej w pamięci immunologicznej. Jego działanie odpowiada wtórnej reakcji immunologicznej układu odpornościowego.

## Rozdział 2 Metody nadrzędnej regulacji i optymalizacji procesów

W rozdziale tym zostaną przedstawione metody nadrzędnej regulacji i optymalizacji procesów technologicznych. Zastosowanie warstwy regulacji, która jest nadrzędna w stosunku do podstawowego układu sterowania może przynieść znaczne korzyści ekonomiczne w obiektach przemysłowych dużej skali, w których procesy technologiczne charakteryzują się wysokim stopniem złożoności i wielowymiarowością. Regulatory PID składające się na warstwę regulacji bezpośredniej nie są w stanie zapewnić wysokiej jakości regulacji w sytuacji, gdy proces technologiczny posiada istotnie nieliniowe charakterystyki, długi czas odpowiedzi wyjść obiektu na zmianę sterowania, znaczną liczbę wejść sterowanych i zakłóceń oraz niemożliwe do pominięcia transmitancje skrośne. Ponadto charakterystyki procesów technologicznych zmieniają się w raz z upływem czasu, co wynika ze zużycia urządzeń wykonawczych i instalacji technologicznej składającej się na obiekt regulacji, zmian właściwości chemicznych używanych substratów, oraz zmian warunków zewnętrznych. W przypadku procesów technologicznych posiadających wymienione właściwości, algorytmy nadrzędnej warstwy regulacji są w stanie zwiększyć jakość regulacji w nominalnym zakresie pracy obiektu. Wynika to z tego, że metody te:

- uwzględniają wielość celów optymalizacji, które często są wzajemnie sprzeczne;
- uwzględniają ograniczenia nakładane zarówno na wejścia, jak i na wyjścia obiektu;
- uwzględniają nieliniowości istniejące w obiekcie;
- posiadają wielowymiarowy, dynamiczny (w przypadku metod regulacji predykcyjnej) lub statyczny (w przypadku metod optymalizacji bieżącej punktu pracy) model obiektu regulacji.



Rysunek 2.1 Obiektu regulacji i związane z nim wektory wejściowe i wyjściowe

Głównym celem metod regulacji nadrzędnej jest poprawa jakości regulacji osiągnięta w warunkach pracy zbliżonych do nominalnych.

Na 2.1 został w sposób uproszczony przedstawiony obiekt regulacji wraz z wektorami reprezentującymi wejścia i wyjścia obiektu. W niniejszej rozprawie przyjęto następujące oznaczenia:

- wektor  $x$  reprezentuje sterowane wejścia obiektu;
- wektor  $z$  reprezentuje niesterowane, mierzone wejścia obiektu (mierzone zakłócenia);
- wektor  $d$  reprezentuje niesterowane wejścia, które są niemierzalne, rzadko mierzone lub nieuwzględniane w zadaniu optymalizacji;
- wektor  $y$  reprezentuje wyjścia obiektu regulacji.

Rozpatrując zadanie wdrożenia rozwiązania opartego na jednej z metod regulacji nadrzędnej należy pamiętać o wielu inżynierskich problemach takich jak: zaszumienie sygnałów pomiarowych, awarie urządzeń wykonawczych oraz oscylacje sygnałów wynikające z niedostatecznego zestrojenia klasycznego układu regulacji.

## 2.1 Algorytm regulacji MPC

Algorytm regulacji MPC (ang. Model Predictive Control) należy do grupy metod *zaawansowanej regulacji*. Metody regulacji predykcyjnej wywarły olbrzymi wpływ na rozwój przemysłowych układów regulacji oraz na kierunek prac badawczych w tym obszarze. Poniżej przedstawiono trzy główne powody, dzięki którym algorytmy MPC osiągnęły niekwestionowany sukces w zastosowaniach przemysłowych [100]:

- możliwość uwzględnienia ograniczeń sygnałów sterujących i sygnałów wyjściowych;



- generowane przez algorytm MPC sterowania uwzględniają nie tylko wspomniane wcześniej ograniczenia, ale również interakcje wewnętrzne istniejące w obiekcie;
- zasada działania regulacji predykcyjnej jest stosunkowo łatwa do wytłumaczenia kadrze inżynierskiej i operatorskiej, która bezpośrednio odpowiada za prowadzenie procesu.

Historia algorytmów MPC sięga końca lat siedemdziesiątych ubiegłego wieku. Od tego czasu algorytmy regulacji predykcyjnej są nieustannie rozwijane i mimo upływu trzech dekad wciąż cieszą się niegasnącym zaufaniem klientów przemysłowych. Istnieje wiele udanych wdrożeń regulatorów MPC w różnych gałęziach przemysłu [86]. Zdecydowana większość rozwiązań informatycznych mających na celu usprawnienie procesów technologicznych polega na strojeniu podstawowych struktur regulacji i/lub na implementacji regulatora predykcyjnego. W kolejnych podrozdziałach zostanie omówiona teoria regulatorów MPC. Krótkie wprowadzenie do koncepcji regulacji predykcyjnej jest niezbędne ze względu na konieczność wykazania tezy roboczej 1.2.3 sformułowanej w rozdziale 1.

### 2.1.1 Ogólna koncepcja regulacji predykcyjnej

Metody regulacji predykcyjnej z przesuwającym horyzontem wykorzystują dynamiczny model obiektu (liniowy lub nieliniowy) do wyznaczenia trajektorii sygnałów sterujących optymalizujących wskaźnik jakości na pewnym horyzoncie czasu. Zgodnie z zasadą sterowania repetycyjnego [82] w każdym kroku algorytmu na podstawie:

- dynamicznego modelu obiektu, zakładającego określony model zakłóceń;
- aktualnych i poprzednich wartości zmiennych wyjściowych;
- poprzednich wartości sterowań;
- przyszłej trajektorii (znanej lub założonej) wartości zadanych regulowanych wyjść obiektu;
- założonych celów regulacji zdefiniowanych w formie wskaźnika jakości;

wyznaczane są wartości elementów wektora sterowań w kolejnych chwilach czasu  $x(k)$ ,  $x(k+1)$ , ...,  $x(k+N_s-1)$ , gdzie  $k$  oznacza aktualną chwilę czasową, a  $N_s$  to horyzont sterowania. W każdej chwili  $k$  używany jest tylko pierwszy wektor sterowań  $x(k)$

będący elementem obliczonej trajektorii sterowań. W kolejnej iteracji algorytmu cała procedura jest powtarzana z uwzględnieniem faktu, że horyzont predykcji i sterowania jest przesunięty o jeden krok w czasie. Wyznaczona przez algorytm MPC trajektoria sygnału sterującego minimalizuje różnicę między prognozowaną (na horyzoncie predykcji) trajektoria wyjść obiektu, a znaną lub założoną trajektoria wartości zadanych tych wyjść. Ponadto kształt trajektorii sterowania zależy także od kary jaką narzuci się na zmienność sygnałów sterujących. Standardowa postać minimalizowanej przez algorytm MPC funkcji celu ma następującą postać

$$J_k = \sum_{s=N_d}^{N_p} \left\| y_{k+s|k}^{sp} - \hat{y}_{k+s|k} \right\|_Q^2 + \sum_{s=0}^{N_s-1} \left\| \Delta x_{k+s|k} \right\|_R^2 \quad (2.1)$$

gdzie:

- $N_s$  – horyzont sterowania,
- $N_p$  – horyzont predykcji,
- $N_d$  – wartość najmniejszego opóźnienia w obiekcie zwiększonego o jeden,
- $y_{k+p|k}^{sp}$  – predykcja wartości zadanych (na chwilę  $k + p$ , liczona w chwili  $k$ ) wyjść obiektu,
- $\hat{y}_{k+p|k}$  – predykcja wyjść obiektu,
- $\Delta x_{k+p|k}$  – predykcja zmian wartości sygnału sterującego, długość trajektorii równa jest długości horyzontu sterowania,
- $Q$  – kwadratowa, zazwyczaj diagonalna macierz wag sygnału wyjściowego, która pozwala na różnicowanie wpływu poszczególnych wyjść na wartość wskaźnika jakości,
- $R$  – kwadratowa, zazwyczaj diagonalna macierz wag sygnału sterującego, która pozwala na różnicowanie wpływu zmienności poszczególnych sygnałów sterujących na wartość wskaźnika jakości.

Macierz  $Q$  reprezentuje wagi z jakimi karane są odchyłki predykowanej trajektorii wyjść obiektu od zadanej trajektorii wyjść. Macierz  $R$  pozwala na zdefiniowanie wag z jakimi karana będzie zmienność trajektorii sygnałów sterujących. Przedstawiony wskaźnik jakości nie jest jedyną dopuszczalną formą. Istnieje możliwość innego zdefiniowania celów optymalizacji, jednak nie wnosi to zmian do istoty koncepcji regulacji predykcyjnej.

### 2.1.2 Realizacje algorytmów regulacji predykcyjnej

Główna różnica między różnymi realizacjami algorytmów regulacji predykcyjnej, wykorzystującymi liniowe modele obiektu, polega na założeniu różnej postaci tych modeli. W algorytmach DMC (ang. Dynamic Matrix Control) model obiektu regulacji wyrażony jest w postaci dyskretnych odpowiedzi skokowych. Model taki może być skonstruowany poprzez wykonanie szeregu eksperymentów identyfikacyjnych polegających na podaniu na wejście obiektu wymuszenia skokowego i rejestracji dynamicznej odpowiedzi obiektu. Algorytmu DMC jest jednym z pierwszych algorytmów regulacji predykcyjnej z przesuwającym horyzontem. Został on opracowany pod koniec lat siedemdziesiątych ubiegłego wieku, a pierwsze publikacje dotyczące wdrożenia tego algorytmu pochodzą z 1980 roku [22, 84]. Swoją dużą popularność algorytm DMC zawdzięcza głównie prostocie modelowania. Ponadto, jako jeden z najstarszych regulatorów predykcyjnych jest dobrze poznany i przetestowany. Więcej informacji na temat algorytmu DMC można znaleźć w [100].

Kolejną metodą realizującą regulację predykcyjną jest algorytm GPC (ang. Generalized Predictive Control) [21]. W algorytmie tym dynamiczny model obiektu zdefiniowany jest w postaci transmitancji dyskretnych (równań różnicowych). Przyjęcie takiego modelu jest bardziej zwarte i oszczędne w porównaniu do algorytmu DMC. Ponadto istnieje możliwość uwzględnienia szerszej klasy modeli zakłóceń [100]. Więcej na temat algorytmów GPC można znaleźć w [13].

Aktualnie w pracach badawczych dotyczących algorytmów MPC dominuje podejście polegające na zastosowaniu modelu w postaci równań stanu. Przykładem takiego rozwiązania jest algorytm SMOC [66]. Model w postaci równań stanu pozwala na wygodną analizę teoretyczną algorytmów MPC. W zastosowaniach przemysłowych zbudowanie modelu w postaci równań stanu nie jest jednak naturalnym podejściem. Przesądza to o mniejszej popularności tego typu rozwiązań w porównaniu do algorytmów DMC i GPC.

### 2.1.3 Algorytmy regulacji predykcyjnej dla obiektów nieliniowych

Przedstawione w poprzednim podrozdziale algorytmy predykcyjne z liniowym modelem obiektu stanowią ważny wkład w rozwój metod regulacji zaawansowanej. Należy jednak pamiętać, że rzeczywiste obiekty mogą wymagać opisu w postaci modelu

nieliniowego. Zastosowanie liniowych modeli do regulacji istotnie nieliniowych obiektów może nie dawać zadowalających rezultatów.

Naturalnym podejściem pozwalającym uwzględnić nieliniowości optymalizowanego procesu jest użycie nieliniowego modelu. Wówczas predykcja wyjść w algorytmie MPC odbywa się w oparciu o model nieliniowy. Obiecującym kierunkiem badań wydaje się być wykorzystanie Sztucznych Sieci Neuronowych [76, 39, 95, 78] do modelowania nieliniowości obiektu. Algorytmy MPC wykorzystujące Sztuczną Sieć Neuronową zostały opisane w [102, 100, 29, 3, 80, 61]. Podstawowym problemem dotyczącym algorytmów MPC z pełnym nieliniowym modelem jest dobranie odpowiedniej metody minimalizacji wskaźnika jakości. Zadanie optymalizacji w takim przypadku jest niekwadratowe i w ogólności nie wypukłe.

Podejściem częściej stosowanym w praktyce są metody wykorzystujące linearyzację modelu nieliniowego w otoczeniu aktualnego punktu pracy [100, 40, 72, 68, 6]. Wówczas trajektoria sterowania wyznaczana jest w oparciu o liniowy algorytm MPC. Rozwiązanie znalezione w oparciu o taką metodę jest suboptymalne, ale zapewniona jest istotna z punktu widzenia zastosowań przemysłowych cecha niezawodności wyznaczania sterowania. Rozszerzeniem powyższych rozważań jest metoda polegająca na wykorzystaniu zlinearyzowanego modelu jedynie do rozwiązania zadania optymalizacji. Swobodna trajektoria predykowanych wyjść [100] wyznaczana jest wówczas w oparciu o model nieliniowy. Więcej na ten temat można znaleźć w [40, 68, 36, 61].

Dużą popularnością w zastosowaniach przemysłowych cieszy się pomysł wykorzystania teorii logiki rozmytej [122, 121] do projektowania nieliniowych regulatorów MPC. Szczególnie interesujące są modele rozmyte typu TS (Takagi-Sugeno), w których następnikiem reguły jest model liniowy [96, 82]. Kluczowym elementem modeli rozmytych typu TS jest zbiór reguł (baza wiedzy), w którym każda reguła posiada następnik w postaci funkcji. Przykład takiej reguły został przedstawiony poniżej:

$$R^i : \text{JEŚLI } x_1 \text{ jest } F_1^i \text{ I } x_2 \text{ jest } F_2^i \text{ I } \dots \text{ I } x_n \text{ jest } F_n^i \text{ TO } y_i = f(x_1, x_2, \dots, x_n)$$

Najczęściej przyjmuje się, że funkcja następnika jest liniowa. W oparciu o model TS można zbudować quasi-liniowy (kawałkami liniowy) regulator MPC. W takim przypadku dla każdej ze zdefiniowanych partycji rozmytych określa się równanie różnicowe realizujące algorytm regulacji. Zdefiniowanie partycji rozmytych zależy od rozpatrywanego problemu. Najczęściej zmiennymi rozmywającymi są sygnały o nieliniowych charakterystykach, definiujące punkt pracy procesu technologicznego. Istnieje także inna metoda projektowania rozmytych regulatorów predykcyjnych. W rozwiązaniu

tym przyjmuje się, że baza wiedzy składa się z reguł, w których następnikami są parametry regulatora predykcyjnego. Poprzez parametry rozumiane są nie tylko wagi, ale również modele obiektu. W takim podejściu wzory ogólne reprezentujące prawo regulacji nie zmieniają się.

#### 2.1.4 Sposoby uwzględnienia niedokładności modelu

Kluczowym elementem regulatora MPC jest model obiektu. Jeżeli dokładność tego modelu jest niewystarczająca, wówczas jakość regulacji może nie być satysfakcjonująca, w szczególności może nawet być gorsza niż w przypadku klasycznych układów regulacji opartych na regulatorach PID. Jednym z kluczowych problemów dotyczących regulacji, w tym także regulacji predykcyjnej, jest zapewnienie bezpieczeństwa i odpowiednio wysokiej jakości regulacji w sytuacji niewystarczającej dokładności modelu. Można wyróżnić dwa główne podejścia, w których uwzględnia się niedokładność modelu: regulacja adaptacyjna (ang. adaptive control) i regulacja odporna (ang. robust control). W podejściu adaptacyjnym [46, 75] w oparciu o sygnały sterujące, wyjściowe i zakłócenia dokonuje się bieżącej identyfikacji modelu. Nowy zidentyfikowany model jest wykorzystywany do wyznaczenia optymalnego wektora sterowań. Wykorzystanie technik regulacji adaptacyjnej jest szczególnie pożądane dla obiektów, których charakterystyki istotnie zmieniają się wraz z upływem czasu. Główne problemy dotyczące bieżącej identyfikacji modelu to:

- wyznaczenie parametrów modelu przy niewystarczającej zmienności sygnałów, w obecności szumów pomiarowych [59];
- wyznaczenie parametrów modelu podczas pracy w zamkniętej pętli sprzężenia zwrotnego [46, 92];
- stosunkowo duży nakład mocy obliczeniowych potrzebny podczas pracy w trybie on-line.

Obserwuje się ciągły rozwój prac badawczych poświęconych eliminacji powyższych niedogodności [59, 42]. Mimo to zaimplementowanie metod adaptacji ciągle jest jeszcze zadaniem trudnym i często metody te nie spełniają pokładanych w nich nadziei.

Regulacja odporna polega na uwzględnieniu niedokładności modelu podczas projektowania i strojenia regulatora [19, 82]. Przy tym podejściu regulatory projektowane są na ogół na najgorszy przypadek, co z reguły skutkuje dużą zachowawczością

działania i niską efektywnością pracy w warunkach zbliżonych do nominalnych. Najbardziej obecnie rozwijaną metodą odpornej regulacji predykcyjnej jest optymalizacja min-max [54, 71, 62]. Metoda ta zakłada możliwość zmian obiektu w każdym kroku algorytmu. Przyjmuje się, że obiekt może zmieniać się w sposób najbardziej niedogodny i dla tego najgorszego scenariusza rozwiązuje się zadanie optymalizacji. Oprócz wymienionej wyżej metody istnieją inne techniki projektowania odpornych regulatorów:

- zapewnienie zachowania zapasu modułu i fazy;
- minimalizacja wskaźnika jakości polegająca na minimalizacji wartości oczekiwanej dla założonego stochastycznego modelu niepewności [65];
- inne [48, 14, 10].

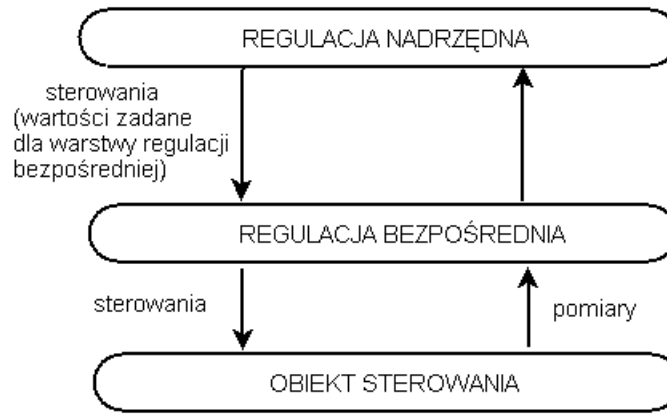
Praktyczne wykorzystanie wymienionych technik, w szczególności najbardziej popularnej metody optymalizacji min-max, jest mocno ograniczone ze względu na:

- trudności związane z projektowaniem tego typu regulatorów;
- konieczność znajomości dobrych modeli niepewności - warunek trudny do spełnienia w rzeczywistych warunkach przemysłowych;
- dużą złożoność obliczeniową.

Analizując wdrożenia regulatorów MPC do regulacji procesów technologicznych, można dojść do wniosku, że z praktycznego punktu widzenia najważniejszym parametrem decydującym o odporności regulatora MPC są wartości kar występujących we wskaźniku jakości, związane ze zmiennością sygnału sterującego.

### **2.1.5 Regulator MPC w warstwowej strukturze sterowania**

Regulatory MPC w zastosowaniach przemysłowych z reguły implementowane są w warstwie regulacji nadrzędnej. W warstwowym układzie regulacji (rys. 2.2) warstwa regulacji bezpośredniej odpowiedzialna jest za bezpieczeństwo przebiegu procesów dynamicznych. We współczesnych systemach automatyki warstwa regulacji bezpośredniej realizowana jest przez rozproszone systemy automatyki (ang. DCS - Distributed Control System). Są to komputerowe systemy przetwarzania informacji realizujące



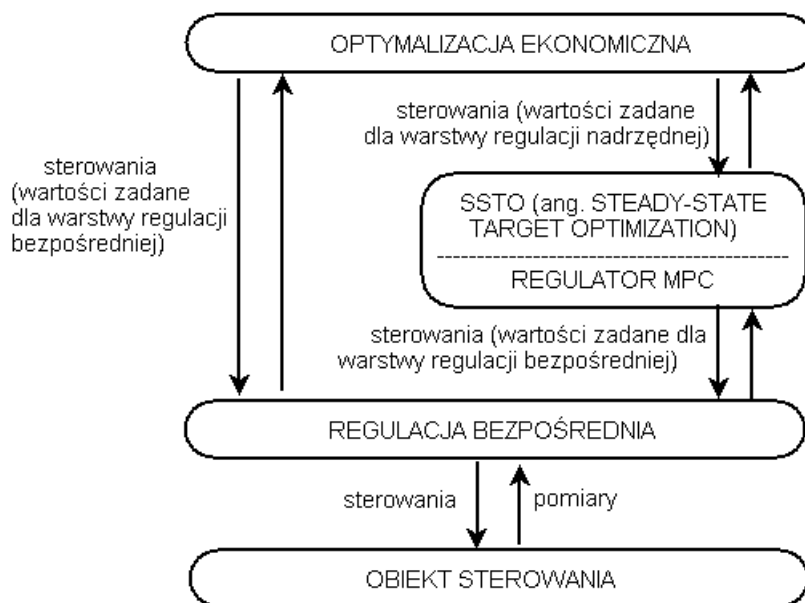
Rysunek 2.2 Warstwowa struktura regulacji

zadania sterowania, wizualizacji i archiwizacji danych procesu przemysłowego. Systemy te posiadają zwykle własne, zintegrowane systemy SCADA (ang. Supervisory Control and Data Acquisition). Charakterystycznymi cechami systemów DCS są:

- sprawna obsługa dużych obiektów przemysłowych;
- obsługa urządzeń pomiarowych i wykonawczych wykorzystujących różne standardy komunikacyjne;
- archiwizacja danych i zdarzeń;
- wizualizacja procesu ułatwiająca operatorski i inżynierski nadzór nad procesem;
- możliwość załadowania i modyfikacji układów sterowania bez zatrzymywania procesu;
- redundancja takich elementów systemu jak: stacje operatorskie, kontrolery, układy wejść-wyjść.

Więcej na temat budowy systemu DCS można znaleźć w [52, 105, 106, 107]. Ze względu na wymóg niezawodności, szybkości działania i stosunkowej prostoty wykorzystywanych algorytmów, w warstwie regulacji bezpośredniej dominują regulatory typu PID [5, 91]. Wykorzystywane są również pewne modyfikacje tych regulatorów takie jak:

- regulacja PID z korekcją od sygnału zakłócenia - sterowanie typu feedforward [77, 45];



Rysunek 2.3 Regulator MPC i algorytm SSTO w warstwowej strukturze regulacji.

- regulacja PID ze zmiennym wzmocnieniem (tzw. gain scheduling) [123].

W ostatnich latach obserwuje się także próby wykorzystania prostych algorytmów predykcyjnych w warstwie regulacji bezpośredniej systemu DCS [82, 83].

Celem warstwy regulacji nadrzędnej [100] jest kontrola zmiennych wielkości procesowych, charakteryzujących się wolniejszymi zmianami i decydujących o jakości i parametrach produkcji. Okres próbkowania warstwy regulacji nadrzędnej jest istotnie większy w porównaniu do warstwy regulacji bezpośredniej. Zmiany wektora zmiennych sterujących następują zdecydowanie rzadziej niż w warstwie regulacji bezpośredniej. Sterowania obliczone w warstwie regulacji nadrzędnej stanowią zazwyczaj wartości zadane dla regulatorów warstwy regulacji bezpośredniej. Warstwa regulacji nadrzędnej, przy założeniu dokładnego modelu obiektu, pozwala na osiągnięcie wyraźnej poprawy jakości regulacji w stanach pracy zbliżonych do nominalnych. Niezawodność i bezpieczeństwo regulacji zapewnione jest przez warstwę regulacji bezpośredniej, która jest w stanie skutecznie reagować na szybkozmienne zakłócenia.

Wartości zadane dla regulatora MPC mogą być obliczane przez warstwę optymalizacji ekonomicznej (patrz podrozdział 2.2). Zadaniem regulatora MPC jest wówczas



utrzymywanie optymalnego punktu pracy. Metody optymalizacji statycznej zaimplementowane w warstwie optymalizacji ekonomicznej, obliczają nowy, optymalny punkt pracy z istotnie mniejszą częstotliwością niż częstotliwość z jaką regulator MPC wyznacza nowe sterowania. Implementacja warstwy statycznej optymalizacji punktu pracy ma sens wówczas jeżeli zakłócenia oddziałujące na proces zmieniają się szybko, ale rzadko lub zakłócenia zmieniają się w sposób ciągły, ale zmiany te są istotnie wolniejsze w porównaniu do dynamiki obiektu. Należy jednak zauważyć, że jeżeli dynamika zmian zakłócenia jest równa lub niewiele mniejsza od dynamiki obiektu regulacji, wówczas warstwa optymalizacji ekonomicznej może nie spełniać pokładanych w niej nadziei, ze względu na zbyt długi okres zmian wartości zadanych dla regulatora MPC. Skrócenie tego okresu jest często niemożliwe ze względu na wykorzystanie złożonego, nieliniowego modelu obiektu, oraz ze względu na wykorzystywane algorytmy adaptacji. Rozwiązaniem jest zaimplementowanie algorytmu SSTO (ang. steady-state target optimization) [100, 11, 49], który pracuje z tą samą częstotliwością zmian sterowania, co algorytm MPC (patrz rys. 2.3). Zadaniem algorytmu SSTO jest przeliczanie optymalnych wartości zadanych dla regulatora MPC, w taki sposób aby uwzględnić zmiany zakłócenia, które nastąpiły pomiędzy kolejnymi zmianami punktu pracy obliczonego w warstwie ekonomicznej optymalizacji punktu pracy.

### 2.1.6 Niepożądane właściwości podejścia MPC

Algorytmy MPC są bezsprzecznie najpopularniejszymi rozwiązaniami implementowanymi w warstwie regulacji nadrzędnej, służącymi do zaawansowanej regulacji procesów przemysłowych [87]. Pomimo licznych zalet, potwierdzonych w zastosowaniach praktycznych, regulatory predycyjne posiadają kilka niepożądanych właściwości:

- wysoki koszt wdrożenia, związany z koniecznością przeprowadzenia testów parametrycznych obiektu regulacji oraz budowy dynamicznego modelu obiektu;
- zaimplementowanie efektywnej metody adaptacji jest zadaniem trudnym i często nie przynosi spodziewanych rezultatów.

Wysoki koszt wdrożenia wynika z konieczności budowy modelu obiektu. W przypadku istotnie nieliniowych charakterystyk obiektu, występuje konieczność stworzenia modelu nieliniowego. Najczęściej wykorzystuje się wówczas quasi-liniowy model rozmyty [82]. Przy takim podejściu należy zbudować kilka liniowych modeli dynamicznych, dla różnych typowych punktów pracy. Wiąże się to z koniecznością wykonania

czasochłonnych testów parametrycznych obiektu, dla każdej partycji rozmytej. Aby zwiększyć dokładność modeli, należy dokonać takiego podziału na partycje rozmyte, który byłby zdefiniowany przez możliwie dużo sygnałów o nieliniowej charakterystyce, które definiują punkt pracy. W praktyce zakłada się gorszą jakość modelowania i definiuje się takie rozmycie modeli, które nie spowoduje powstania dużej liczby partycji rozmytych. Uwzględnienie dodatkowych sygnałów jako zmiennych rozmywających powoduje, że ilość niezbędnych do stworzenia modeli wyraźnie wzrasta. Pociąga to za sobą konieczność przeprowadzania odpowiednio większej ilości testów obiektu regulacji, co negatywnie wpływa na i tak już wysoki koszt wdrożenia.

Parametryczne testy obiektu regulacji pochłaniają znaczną część czasu wdrożenia regulatora MPC. Koszty pracy wysoko wykwalifikowanej kadry inżynierskiej stanowią znaczne obciążenie dla budżetu zakładu przemysłowego. Głównym składnikiem ceny współcześnie oferowanych regulatorów MPC jest koszt pracy inżyniera wdrażającego regulator predykcyjny. Koszt samego komputera jak i instalacji oprogramowania realizującego regulację predykcyjną jest zdecydowanie mniejszy niż koszt pracy kadry inżynierskiej wykonującej parametryczne testy obiektu i budującej na ich podstawie model (często nieliniowy) obiektu. Według danych firmy Transtition Technologies S.A. 60 % ceny współcześnie sprzedawanych regulatorów MPC związane jest z koniecznością budowy modelu optymalizowanego procesu. Badania przeprowadzone przez firmę Honeywell wykazały, że koszt budowy dynamicznego modelu obiektu wynosi od 250 USD do 1000 USD dla każdej pojedynczej zależności między wejściem i wyjściem obiektu [27]. W przypadku obiektu składającego się z dziesięciu wejść sterowanych, pięciu wejść niesterowanych i czterech wyjść (średni wymiar zadania optymalizacji procesu spalania zachodzącego w kotle energetycznym), koszt budowy dynamicznego modelu wynosi więc od 15000 USD do 60000 USD.

Oprócz problemów natury ekonomicznej związanych z kosztem pracy kadry inżynierskiej dochodzą jeszcze problemy związane z nieefektywnym prowadzeniem procesu technologicznego podczas przeprowadzanych testów. Konieczność zapewnienia odpowiedniego stanu procesu na czas przeprowadzania testów (np: stałe, zadane obciążenie bloku energetycznego w przypadku optymalizacji procesu spalania w kotle energetycznym lub odpowiednie stężenie substratu w przypadku optymalizacji procesów chemicznych) powoduje znaczne straty finansowe zakładu przemysłowego. Oprócz konieczności spełnienia wymogów co do wartości sygnałów zakłóceń mierzonych sam

charakter testów może doprowadzić do strat finansowych spowodowanych nieoptymalnym sterowaniem procesem, prowadzącym do niskiej efektywności produkcji. Ponadto dla pewnych obiektów niemożliwe jest wykonanie testów we wszystkich założonych punktach pracy. Wynika to z awarii urządzeń wykonawczych lub pomiarowych, oraz z konieczności spełnienia wymogów bezpieczeństwa. Należy również pamiętać, że na proces technologiczny cały czas oddziałują pewne niemierzalne, rzadko mierzone lub nieuwzględniane zakłócenia takie jak: warunki zewnętrzne (np.: temperatura i wilgotność powietrza), właściwości chemiczne używanych substratów (np.: kaloryczność paliwa) i sprawność urządzeń wykonawczych. Model zidentyfikowany na podstawie danych pochodzących ze stosunkowo krótkiego odcinka czasu (w porównaniu do planowanej długości czasu pracy regulatora MPC) może nie być dokładny w sytuacji, gdy oddziałujące na proces niemierzalne lub nieuwzględniane zakłócenia przyjmują wartości inne niż te, które oddziaływały na proces w trakcie identyfikacji modelu.

Z rozważań przeprowadzonych w rozdziale 2.1.4 wynika, że implementacja efektywnego algorytmu adaptacji w regulatorze predykcyjnym przysparza wiele problemów, w kontekście zastosowań praktycznych. Należy jednak pamiętać, że charakterystyki procesów technologicznych podlegają ciągłym zmianom. Związane jest to ze zużyciem urządzeń wykonawczych i instalacji składającej się na obiekt regulacji oraz zmianami parametrów substratów używanych w procesie. Widać więc, że w zadaniu optymalizacji procesów technologicznych występuje silna potrzeba uaktualniania stanu wiedzy na temat rozpatrywanego procesu.

Wymienione w rozdziale 2.1.6 mankamenty regulacji predykcyjnej, prowadzą do wniosku, że konieczne jest podjęcie badań nad znalezieniem rozwiązania tańszego, które w sposób efektywny będzie realizowało zadania zdobywania wiedzy o procesie i adaptacji do nowych warunków pracy. Wydaje się, że bardzo pomocne w realizacji tego zadania mogą być mechanizmy zaczerpnięte z obserwacji działania układu odpornościowego żywych organizmów. Należy pamiętać, że ciągła nauka i podnoszenie zdolności obronnych organizmu, to podstawowe cechy układu odpornościowego (patrz rozdział 3). Automatyczne zdobywanie wiedzy o optymalizowanym procesie może wyeliminować czynnik ludzki z takich zadań jak: przeprowadzanie parametrycznych testów obiektu i budowa modelu obiektu regulacji. To z kolei spowoduje redukcję czasu pracy przeznaczonego na wdrożenie nadrzędnego algorytmu regulacji.

W rozprawie tej wykazano, że w przypadku pewnej szczególnej klasy procesów, dla których istotne zakłócenia oddziałujące na proces znajdują się na w przybliżeniu

stałym poziomie przez czas dłuższy niż czas potrzebny na ustalenie się odpowiedzi obiektu na zmianę sterowania, możliwe jest wykorzystanie mechanizmów inspirowanych działaniem układu odpornościowego do bieżącej optymalizacji punktu pracy procesu technologicznego. W przypadku takich procesów rozwiązanie SILO stanowi tanią w sensie ekonomicznym alternatywę dla regulatorów MPC. W rozwiązaniu tym nie występuje potrzeba przeprowadzenia czasochłonnej procedury identyfikacji obiektu i budowy modeli matematycznych procesu. Ponadto mechanizm zdobywania wiedzy o procesie i adaptacji do nowych warunków pracy stanowi integralny składnik systemu SILO, dzięki czemu adaptacja do niestacjonarnych charakterystyk procesu jest zachowana.

## 2.2 Metody optymalizacji punktu pracy

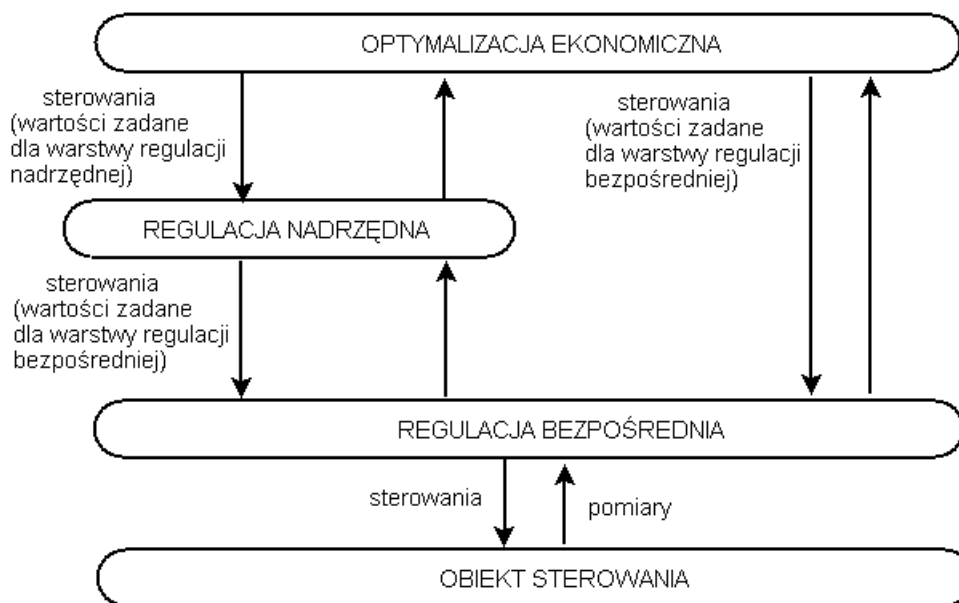
W systemie SILO wykorzystywana jest regulacyjna postać wskaźnika jakości. Przedstawione w niniejszej rozprawie rozwiązanie, na podstawie wiedzy zgromadzonej w pamięci immunologicznej, minimalizuje różnicę między zadaną i zmierzoną (lub estymowaną) wartością wyjść obiektu. Architektura systemu SILO pozwala jednak również na zdefiniowanie ekonomicznego wskaźnika jakości postaci

$$J(c, y) = \sum_{k=1}^{nc} p_j^c c_j - \sum_{k=1}^{ny} p_j^y y_j$$

gdzie:

- $c_j$  –  $j$ -ty element wektora zmiennych decyzyjnych warstwy optymalizacji,
- $p^y$  – wektor cen produktów wyjściowych,
- $p^c$  – wektor cen strumieni surowców i mediów energetycznych.

Ekonomiczna funkcja celu definiuje ekonomiczny cel produkcji (najczęściej zysk). Zdefiniowanie w SILO ekonomicznego wskaźnika jakości, wykorzystując do tego celu definicję wskaźnika jakości (8.1) z rozdziału 8 jest możliwe poprzez przypisanie współczynnikom kary kosztu ekonomicznego, ustawienie zerowych wartości zadanych dla wszystkich elementów wektora sterowań  $x$ , oraz ustawienie na tyle dużych wartości zadanych dla elementów wektora zmiennych wyjściowych, aby wartości te z przyczyn technologicznych nigdy nie były osiągnięte. Widać zatem, że system SILO może być stosowany jako ekonomiczny optymalizator punktu pracy procesów technologicznych.



Rysunek 2.4 Warstwa optymalizacji ekonomicznej w warstwowej strukturze sterowania.

Ze względu na dotychczasowe zastosowania SILO do optymalizacyjnej regulacji punktu pracy procesu spalania w kotle energetycznym, w rozprawie został przedstawiony algorytm wykorzystujący regulacyjną postać wskaźnika jakości. Dla zachowania ogólności opisu w niniejszym rozdziale omówiono metody statycznej optymalizacji punktu pracy i porównano je z podejściem zastosowanym w SILO.

Optymalny wektor zmiennych decyzyjnych, stanowiący rozwiązanie zadania optymalizacji w warstwie optymalizacji ekonomicznej, jest jednocześnie wektorem wartości zadanych dla regulatora warstwy regulacji nadrzędnej. Wybrane elementy optymalnego wektora zmiennych decyzyjnych mogą być też wartościami zadanymi dla regulatorów warstwy regulacji bezpośredniej (rys. 2.4). Implementacja warstwy statycznej optymalizacji może przynieść spodziewane efekty ekonomiczne jeżeli zakłócenia oddziałujące na proces zmieniają się szybko, ale rzadko lub zakłócenia zmieniają się w sposób ciągły, ale zmiany te są istotnie wolniejsze w porównaniu do dynamiki obiektu. Istnieje kilka algorytmów bieżącej optymalizacji punktu pracy [99]. Jednym z nich jest metoda *Powtarzanych Estymacji Parametrów i Optymalizacji* (PEPO) [99]. W metodzie tej dostrojenie punktu pracy do aktualnej sytuacji procesowej następuje w dwóch etapach. W pierwszym etapie dokonywana jest estymacja parametrów modelu

stanu ustalonego. W drugim etapie w oparciu o uaktualniony model rozwiązywane jest zadanie optymalizacji. Wadą tej metody jest konieczność posiadania *a priori* dokładnego modelu obiektu regulacji. Ponadto w warunkach rzeczywistych trudno jest uzyskać dokładny model w szerokim zakresie zmienności punktu pracy, potrzebny do wyznaczenia pochodnych modelu (charakterystyk statycznych).

Kolejną metodą realizującą bieżącą optymalizację punktu pracy jest metoda *Powtarzanej Modyfikowanej Optymalizacji* (PMO) [98]. Metoda ta stanowi rozwinięcie metody zintegrowanej optymalizacji i estymacji parametrów (ang. Integrated System Optimization and Parametric Estimation - ISOPE) [90, 103]. Metoda ISOPE potrafi w sposób iteracyjny osiągnąć rozwiązanie ściśle optymalne, podczas gdy metoda PE-PO prowadziła do rozwiązań suboptymalnych. W metodzie PMO wykorzystywana jest punktowa informacja o wartości pochodnej modelu obiektu. Metoda optymalizacji wykorzystując informacje o pochodnej odwzorowania obiektowego w aktualnym punkcie pracy jest w stanie w sposób iteracyjny osiągnąć punkt optymalny. W metodzie ISOPE estymacja parametrów modelu wykonywana jest w każdym kroku algorytmu, natomiast w metodzie PMO adaptacja modelu nie jest konieczna w każdej iteracji. Podstawową wadą metody ISOPE i PMO jest estymacja wartości pochodnych modelu za pomocą zmian sterowania i rejestracji zmian wyjść procesu. Takie podejście jest kosztowne bo oznacza  $n$  dodatkowych procesów przejściowych, gdzie  $n$  to wymiar wektora sterowań.

W dualnym algorytmie PMO (algorytm DPMO) [99] zastosowano efektywną metodę estymacji pochodnej charakterystyki statycznej. W algorytmie tym wykorzystano koncepcję sterowania dualnego Feldbauma [33]. W metodzie DPMO założono, że dla celów estymacji pochodnej w kolejnych iteracjach, dopuszcza się w danym kroku odstępianie od warunków ścisłej optymalności. Następuje to jednak tylko wtedy, gdy aktywacji ulegną ograniczenia uwarunkowujące. Ograniczenia uwarunkowujące wprowadzone są w celu zapewnienia, że macierz potrzebna do obliczenia pochodnych jest dostatecznie dobrze uwarunkowana. Wprowadzenie powyższych ograniczeń sprawia, że algorytm DPMO ma skomplikowaną, silnie nieliniową strukturę. Istotną wadą tej metody jest konieczność wykonywania wstępnych zmian punktu pracy w początkowej fazie algorytmu. Może to doprowadzić do nieefektywnego prowadzenia procesu. Rozwinięciem metody DPMO jest metoda DPMO+ [99]. W metodzie tej w fazie wstępnej wykorzystano algorytm PEPO. Przy takim podejściu istnieje konieczność posiadania

*a priori* dobrego modelu obiektu. Analizując działanie metody DPMO+ i SILO widać pewne podobieństwa obu metod:

- dbanie o dobre uwarunkowanie macierzy wykorzystywanych w zadaniu optymalizacji;
- adaptacja modelu obiektu do nowych warunków pracy.

Pomimo pewnych podobieństw istnieją zasadnicze różnice pomiędzy metodą DPMO+ i SILO:

- Brak konieczności posiadania *a priori* modelu obiektu regulacji w systemie SILO;
- Wykorzystanie w SILO dwóch rodzajów modeli reprezentujących mniej i bardziej szczegółową wiedzę o statycznych charakterystykach procesu;
- Wykorzystanie w SILO warstwowego algorytmu optymalizacji (rozdział 8). Każda warstwa reprezentuje inną strategię poszukiwania rozwiązywania optymalnego i nauki procesu. Poszczególne warstwy aktywowane są w zależności od posiadanej przez system wiedzy;
- Wykorzystanie w SILO inspirowanych działaniem układu odpornościowego mechanizmów zdobywania wiedzy o procesie (rozdział 7).

Z powyższych rozważań wynika, że użycie mechanizmów inspirowanych działaniem układu odpornościowego do realizacji zadań bieżącej optymalizacji punktu pracy stanowi innowacyjne rozwiązanie, stanowiące wkład autora w dziedzinę bieżącej optymalizacji punktu pracy procesów technologicznych. Ze względu na fakt, że w przedstawionym w niniejszej rozprawie algorytmie optymalizacji wykorzystywanym w SILO przyjęto regulacyjną postać wskaźnika jakości, w dalszej części rozprawy właściwości systemu SILO będą porównywane z właściwościami metod opartych na algorytmie MPC.

## Rozdział 3 Sztuczne Systemy Immunologiczne

W książce [26] Dąbrowski zauważa, że system immunologiczny, podobnie jak system nerwowy, jest szczególnym rodzajem układu, który w toku nauki jest w stanie zdobywać i podnosić swoje kwalifikacje. Ponadto układ odpornościowy posiada pamięć i charakteryzuje się umiejętnością przewidywania. Potrafi rozwijać nowe zdolności, ale może również stracić stare, nieprzydatne umiejętności. Wymienione przez Dąbrowskiego cechy układu odpornościowego doskonale przydają się w rozwiązywaniu różnorodnych problemów technicznych, również tych z zakresu optymalizacji procesów technologicznych.

### 3.1 Układ odpornościowy żywych organizmów

Celem działania układu odpornościowego jest ochrona organizmu przed patogenami. Przez termin *patogeny* rozumiane są wirusy, bakterie, pasożyty i inne mikroorganizmy, które zagrażają żywemu organizmowi. Zatem podstawą działania układu odpornościowego jest prawidłowa detekcja patogenów oraz ich efektywna eliminacja. Na powierzchni patogenów znajdują się antygeny, które wywołują reakcję immunologiczną. Antygeny rozpoznawane są przez specjalne detektory - limfocyty. Struktura limfocytów w sposób bezpośredni reprezentuje wiedzę układu odpornościowego [110]. Rozważając budowę układu odpornościowego z punktu widzenia jego przydatności do rozwiązywania problemów technicznych, szczególnie interesujące są limfocyty typu B. Każdy limfocyt typu B może posiadać inny *zestaw narzędzi* do niszczenia patogenów, dzięki czemu jedne limfocyty mogą być skuteczniejsze od innych w zwalczaniu wyróżnionego rodzaju patogenów atakujących organizm. Narzędziami używanymi do walki z patogenami są przeciwciała produkowane przez limfocyty typu B. W wyniku rekombinacji genów składających się na genom danego osobnika powstają nowe,



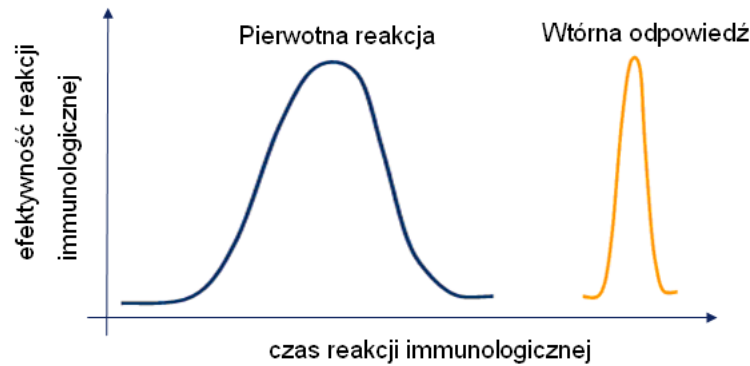
skuteczniejsze generacje przeciwciał, widać więc podobieństwo między układem odpornościowym i systemem ewolucyjnym.

Nowe limfocyty typu B powstają w szpiku kostnym. Proces powstawania limfocytów w szpiku kostnym nie jest związany z oddziaływaniem antygenów. Nowe limfocyty typu B mogą także powstać pod wpływem stymulacji antygenami w procesie *selekcji klonalnej* [93]. W procesie tym aktywowane limfocyty typu B podlegają intensywnemu różnicowaniu i proliferacji. W wyniku tego procesu powstaje duża liczba klonów zdolnych do związania antygenów wytworzonych przez patogeny atakujące organizm. Po wyeliminowaniu patogenu limfocyty typu B ulegają apoptozie, ale nie-liczne przeżywają jako komórki tworzące pamięć immunologiczną. Próbę wyjaśnienia mechanizmów tworzenia tej pamięci stanowi hipoteza sieci idiotypowej [43]. Dzięki informacjom zawartym w pamięci immunologicznej kolejna reakcja organizmu na atak podobnego patogenu jest szybsza i skuteczniejsza. Jest to tak zwana wtórna reakcja immunologiczna.

Oprócz limfocytów typu B istnieją także limfocyty typu T. Głównym zadaniem limfocytów typu T jest rozpoznawanie obcych komórek w organizmie oraz inicjalizacja i koordynacja odpowiedzi immunologicznej, w której uczestniczą m.in. limfocyty typu B. Ważną z punktu widzenia niniejszej rozprawy podgrupą limfocytów typu T są limfocyty wspomagające  $T_h$ . Ich zadaniem jest aktywacja limfocytów typu B.

Układ odpornościowy jest wielowarstwowym systemem obronnym organizmu. Pierwsze dwie warstwy chroniące organizm to skóra i bariera fizjologiczna (pH, lzy, temperatura ciała itp.). Kolejną warstwą jest wrodzony układ odpornościowy. Rodząc się człowiek posiada już wrodzoną odporność. W trakcie życia układ ten nie jest w żaden sposób modyfikowany. Jego zadaniem jest natychmiastowe rozpoczęcie akcji obronnej. W tym celu wykorzystywane są komórki żerne oraz układ dopełniacza. Natychmiastowa akcja obronna wrodzonego układu odpornościowego zapewnia czas niezbędny na uaktywnienie właściwych mechanizmów obronnych czwartej warstwy - warstwy adaptacji. Pierwsze trzy wymienione warstwy składają się na tzw. odporność nieswoistą. Z punktu widzenia nauk technicznych szczególnie interesująca jest odporność swoista, za którą odpowiedzialna jest warstwa adaptacji.

Cechą charakterystyczną warstwy adaptacji jest nieustanne zdobywanie wiedzy i podnoszenie swoich kwalifikacji. Proces uczenia związany jest z tzw. *pierwotną odpowiedzią immunologiczną*. Jest to odpowiedź organizmu na nowy, nieznaną patogen, co w praktyce odpowiada wyszukaniu limfocytów z najlepszym zestawem narzędzi



Rysunek 3.1 Pierwotna i wtórna reakcja immunologiczna

do usunięcia zagrożenia. Pierwotna odpowiedź układu odpornościowego jest na ogół wolna, ponieważ potrzebuje on czasu na eliminację nieznanego patogenu (patrz rys. 3.1). Warto jednak podkreślić, że po udanej akcji obronnej pamięć o patogenie nie zanika. Dzięki temu reakcja na ponowny atak podobnego patogenu jest o wiele szybsza i skuteczniejsza. Jest to tzw. *wtórna reakcja immunologiczna*, która świadczy o posiadaniu przez układ odpornościowy cech systemu adaptacyjnego.

Wymienione dotychczas cechy układu immunologicznego i opis jego działania prowadzą do wniosku, że reakcja obronna organizmu polega na produkcji limfocytów z odpowiedniej grupy. Jednak aby skutecznie zarządzać limfocytami ich liczba nie może rosnąć w nieskończoność. Dzięki mechanizmowi konkurencji struktura pamięci immunologicznej jest strukturą samoregulującą się. Osobniki nieefektywne są usuwane, a w ich miejsce pojawiają się nowe limfocyty. Uproszczony mechanizm zarządzania populacją limfocytów przedstawia poniższe równanie [110]

$$\gamma = \lambda - \delta + \zeta$$

gdzie:

$\gamma$  – stopień różnorodności komórek,

$\lambda$  – dopływ nowych komórek,

$\delta$  – śmierć nieefektywnych komórek,

$\zeta$  – reprodukcja pobudzonych komórek.

Jako podsumowanie niniejszego wprowadzenia do teorii Sztucznych Systemów Immunologicznych, przytoczony zostanie cytat z książki Wierzchonia [110]: *Z tego co*

*jednak wiemy, lub lepiej - przypuszczamy, że wiemy - wyłania się niezwykle atrakcyjny dla informatyków obraz układu odpornościowego jako efektywnego rozproszonego systemu przetwarzania informacji posiadającego zdolność uczenia się i adaptacji do zmiennego otoczenia.*

## 3.2 Zastosowania teorii Sztucznych Systemów Immunologicznych

Teoria Sztucznych Systemów Immunologicznych opiera się na wykorzystaniu wybranych mechanizmów rządzących działaniem układu odpornościowego, do rozwiązywania złożonych problemów. Ta nowa, rozwijana od 15 lat dziedzina nauki, zalicza się do nurtu inspirowanych biologią rozwiązań takich jak Sztuczne Sieci Neuronowe [76, 39, 95, 78] i Algorytmy Genetyczne [2, 7]. Powstało wiele interesujących prac dotyczących Sztucznych Systemów Immunologicznych. Nie da się jednak ukryć, że pomimo kilku udanych rozwiązań w takich dziedzinach jak nawigacja robotów i ochrona systemów informatycznych, liczba wdrożeń Sztucznych Systemów Immunologicznych jest nieproporcjonalnie mała w stosunku do ilości prac poświęconych tej tematyce. Niedostatek praktycznych zastosowań tego typu systemów powoduje, że popularność metod czerpiących inspiracje z działania układu odpornościowego jest zdecydowanie mniejsza niż w przypadku Sztucznych Sieci Neuronowych czy Algorytmów Genetycznych.

Praca [24] stanowi aktualny i bogaty przegląd metod i technik rozwijanych w oparciu o teorię Sztucznych Systemów Immunologicznych. Prace poświęcone zastosowaniom tych systemów w rzeczywistym świecie dotyczą dziedzin takich jak: wykrywanie anomalii [94, 44], rozpoznawanie wzorców [15], eksploracja danych [104], bezpieczeństwo systemów informatycznych [53, 23, 41, 9], wykrywanie błędów [25, 12] i sterowanie adaptacyjne [58, 47]. Z punktu widzenia niniejszej rozprawy pożądane jest omówienie prac wykorzystujących teorię Sztucznych Systemów Immunologicznych w dziedzinie sterowania, w szczególności do regulacji procesów technologicznych. Niestety studia literaturowe prowadzone przez autora wykazały, że liczba publikacji poświęconych wykorzystaniu Sztucznych Systemów Immunologicznych w dziedzinie sterowania jest bardzo mała. Tylko jedna z pośród tych prac doczekała się praktycznej implementacji. W pracach tych podkreśla się jednak bardzo pożądaną zdolność układu odpornościowego do nauki i adaptacji.

Krishnakumar i Neidhoefer w [57] przedstawili swoją koncepcję wykorzystania metod inspirowanych działaniem układu odpornościowego do sterowania helikoptrem UH-1. Metoda ta była przetestowana w oparciu o symulator helikoptera. Główna koncepcja tej pracy opiera się na wykorzystaniu mechanizmów inspirowanych działaniem układu odpornościowego do adaptacji modelu neuronowego wykorzystywanego w układzie sterowania. Autorzy wprowadzili pojęcie bloków konstrukcyjnych (ang. building blocks) Sztucznej Sieci Neuronowej. Blok konstrukcyjny reprezentuje połączenie (lub rodzinę połączeń) między neuronami sieci. Każdy blok konstrukcyjny jest kodowany i traktowany jako molekula DNA. Zadaniem opisanego przez Krishnakumar i Neidhoefer algorytmu jest identyfikacja dobrych bloków konstrukcyjnych i ich złączenie. Rozwiązanie przedstawione w [57] zostało przez tych samych autorów rozwinięte w [56] i w [58]. W publikacjach tych autorzy rozszerzyli koncepcje bloków konstrukcyjnych również na inne klasy modeli (np: systemy rozmyte). Krishnakumar i Neidhoefer traktują pojawienie się zakłócenia jako prezentacje antygeny w układzie odpornościowym. Podobne podejście zostało zaproponowane w systemie SILO, którego dotyczy niniejsza rozprawa. Na podstawie wartości zakłócenia krytyk rozpoczyna proces adaptacji. Parametry regulatora są modyfikowane w taki sposób aby neutralizować zakłócenie. Zaproponowane przez autorów rozwiązanie zostało zastosowane do wyznaczania powietrznej trasy samolotu. Rozpatrując metodę przedstawioną w [56, 57, 58] w kontekście nadrzędnej regulacji procesu technologicznego należy zwrócić uwagę na podstawowe założenia tej metody:

- istnieje *a priori* pewien model reprezentujący obiekt regulacji;
- konieczność zdefiniowania *a priori* pewnej liczby bloków konstrukcyjnych.

Założenia te implikują konieczność wykonania czasochłonnych testów parametrycznych i budowy modelu optymalizowanego procesu. Tak więc rozwiązanie to posiada podstawową wadę regulatorów MPC, która była przyczynkiem do rozpoczęcia prac nad systemem SILO. Założenia te są sprzeczne z tezą roboczą 1.2.3. Ponadto wdrożenie rozwiązania proponowanego przez Krishnakumar i Neidhoefer dodatkowo komplikuje konieczność zdefiniowania algorytmu genetycznego odpowiedzialnego za adaptację. Powyższe rozważania pokazują, że wykorzystanie metody opisanej w [56, 57, 58] do nadrzędnej regulacji procesu technologicznego nie stanowi atrakcyjnej (z ekonomicznego punktu widzenia) alternatywy dla dobrze sprawdzonych i cieszących się dużym zaufaniem przemysłu regulatorów MPC.

Kolejną pracą poświęconą wykorzystaniu teorii Sztucznych Systemów Immunologicznych w dziedzinie regulacji jest [51]. W pracy tej autor przedstawił metodę doboru wzmocnienia regulatora PID wykorzystującą mechanizmy immunologiczne. Metoda ta została przetestowana w oparciu o symulator wykorzystujący uproszczony model obiektu regulacji. Autor zwrócił uwagę na interakcje skrośne występujące między poszczególnymi podsystemami elektrowni, ale zaproponowane przez niego rozwiązanie dotyczy jedynie układów regulacji opartych na regulatorach PID. Tak więc metoda ta nie jest w stanie skutecznie realizować zadań optymalizacji uwzględniającej wiele (często sprzecznych) celów. Nie jest więc możliwe wykorzystanie tego rozwiązania do nadrzędnej regulacji procesu technologicznego.

Ciekawą pracą dotyczącą wykorzystania metod immunologicznych w zagadnieniach regulacji jest [20]. W pracy tej wykorzystano mechanizm układu odpornościowego polegający na regulacji aktywności limfocytów typu B. W zależności od koncentracji antygenów układ odpornościowy jest pobudzany do tworzenia przeciwciał (przez limfocyty  $T_h$ ) lub produkcja przeciwciał jest hamowana (przez limfocyty  $T_s$ ). Traktując koncentrację antygenów jako uchyb regulacji, a koncentracje przeciwciał jako sterowanie, autor zaproponował koncepcję nieliniowego samoadaptującego się regulatora jednopętlowego. Autor dokonał symulacji działania systemu regulacji w oparciu o uproszczony model obiektu regulacji. Praca ta podobnie jak [51] nie rozwiązuje problemu istnienia interakcji skrośnych między zmiennymi sterowanymi i wyjściami procesu. Nie został również poruszony problem regulacji obiektu typu MIMO (ang. Multi Input Multi Output). Metoda zaproponowana w [20] nie nadaje się więc do nadrzędnej regulacji procesów technologicznych.

W pracy [47] zaproponowano wykorzystanie sztucznego systemu immunologicznego do sterowania lotem samolotu Boeing 747. Celem stawianym przez autorów jest utrzymanie wysokości i prędkości lotu przy zmieniających się charakterystykach pracy silnika i turbulencjach atmosferycznych. Dokonano symulacji przedstawionego rozwiązania w oparciu o model lotu Boinga 747. Zaprezentowana metoda wykorzystuje mechanizm układu odpornościowego polegający na rozpoznawaniu obcych komórek. Najpierw tworzony jest zbiór *własnych komórek*. Własna komórka zdefiniowana jest jako stan akceptowalnej pracy regulatora reprezentowany w postaci łańcuchów bitowych, stworzonych na podstawie zarejestrowanych czasowych odpowiedzi systemu. Następnie losowo tworzony jest zbiór receptorów, które nie wiążą łańcuchów bitowych należących do własnych komórek. Jeżeli w trakcie pracy łańcuch bitowy stworzony na

podstawie czasowej odpowiedzi systemu zostanie związany przez receptor, wówczas oznacza to wtargnięcie obcej komórki do organizmu. Innymi słowy oznacza to stan, w którym regulator nie pracuje wystarczająco dobrze. W takiej sytuacji przeszukiwana jest baza rozwiązań przechowująca pary receptor - przeciwciało. Jeżeli receptor pasuje do aktualnego nieakceptowanego stanu pracy regulatora, to następuje bezpośrednie zastosowanie przeciwciała z dostępnej bazy rozwiązań. Przeciwciałem jest wektor parametrów regulatora. W przypadku nie znalezienia w bazie podobnego rozwiązania, przeciwciało wyznaczane jest przez algorytm ewolucyjny. Rozwiązanie zaproponowane w [47] ma pewne cechy powodujące, że zastosowanie tej metody do nadrzędnej regulacji procesu technologicznego jest nieopłacalne i zbyt czasochłonne. Poniżej wymieniono owe niepożądane właściwości:

- konieczność stworzenia dokładnego modelu symulacyjnego obiektu regulacji, a co za tym idzie konieczność przeprowadzenia czasochłonnych testów obiektu;
- konieczność stworzenia regulatora skutecznie realizującego cele regulacji w pewnym zakresie pracy;
- konieczność zdefiniowania początkowego zbioru parametrów regulatora dla różnych odpowiedzi obiektu, które nie odpowiadają normalnej pracy systemu.

Powyższe cechy świadczą o tym, że próba wdrożenia tego systemu do nadrzędnej regulacji procesu technologicznego była by jeszcze bardziej czasochłonna, niż w przypadku regulatorów MPC.

Jak zostało wykazane, pomimo licznych, pożądanых cech układu odpornościowego, nie istnieją Sztuczne Systemy Immunologiczne służące do zaawansowanej regulacji i optymalizacji procesu technologicznego. System SILO jest pierwszym na świecie rozwiązaniem realizującym to zadanie przy wykorzystaniu metod inspirowanych działaniem układu odpornościowego organizmów żywych. Przedstawiony w niniejszej rozprawie system stanowi więc nowatorski wkład autora w dziedzinę Sztucznych Systemów Immunologicznych.

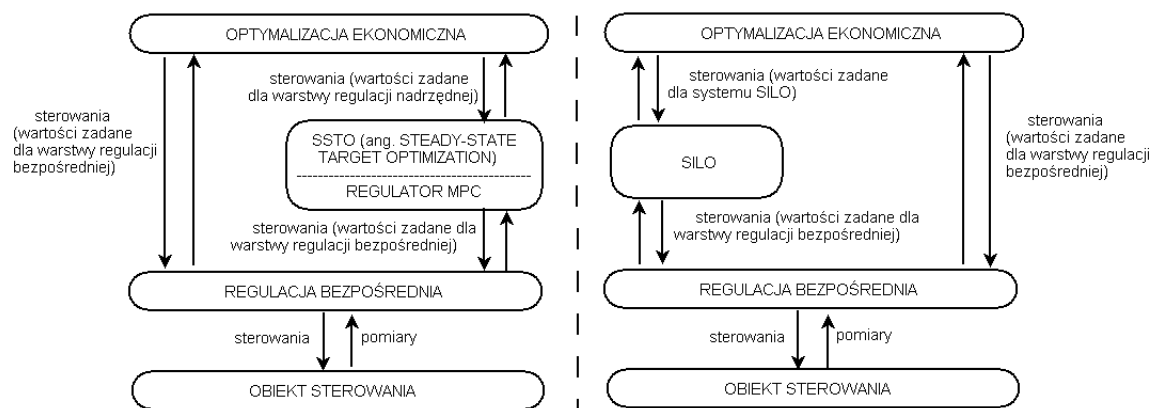
## Rozdział 4 Implementacja systemu SILO w warstwowym układzie regulacji

W warstwowej strukturze sterowania, system SILO, pomimo statycznego modelu obiektu, implementowany jest w tej samej warstwie co algorytmy regulacji predykcyjnej z przesuwającym horyzontem (patrz rys. 4.1). Decyduje o tym regulacyjna postać wskaźnika jakości, wykorzystywana przez SILO. Takie umiejscowienie prezentowanego rozwiązania w warstwowej strukturze sterowania umożliwia wykazanie tezy roboczej 1.2.3, mówiącej o tym, że dla pewnej klasy procesów SILO stanowi tanią w sensie ekonomicznym alternatywę dla algorytmów regulacji predykcyjnej z przesuwającym horyzontem. W rozdziale 2 pokazano, że system SILO może też pracować w warstwie optymalizacji ekonomicznej. Architektura systemu SILO pozwala na zdefiniowanie ekonomicznego wskaźnika jakości. Ze względu jednak na przedstawione w niniejszej rozprawie zastosowanie SILO do optymalizacji procesu spalania w kotle energetycznym, w dalszej części rozprawy założono, że SILO korzysta z regulacyjnej postaci wskaźnika jakości.

Podstawowe układy regulacji w dużych obiektach przemysłowych są najczęściej implementowane w oparciu o rozproszone systemy sterowania DCS (patrz rozdział 2). Ze względu na wymóg niezawodności, szybkości działania i stosunkowej prostoty wykorzystywanych algorytmów, w warstwie regulacji bezpośredniej dominują regulatory typu PID [5, 91]. Wykorzystywane są również pewne modyfikacje tych regulatorów takie jak:

- regulacja PID z korekcją od sygnału zakłócenia - sterowanie typu feedforward [77, 45];
- regulacja PID ze zmiennym wzmocnieniem (tzw. gain scheduling) [123].

Celem działania regulatorów MPC jak i systemu SILO jest realizacja założonych celów



Rysunek 4.1 SILO i MPC w warstwowej strukturze sterowania.

optymalizacji procesu w warunkach nominalnej pracy obiektu. W sytuacjach nietypowych, takich jak na przykład rozruch obiektu, powyższe rozwiązania nie przynoszą poprawy jakości regulacji i najczęściej są wyłączane. Za jakość regulacji w stanach przejściowych odpowiada w głównej mierze warstwa regulacji bezpośredniej.

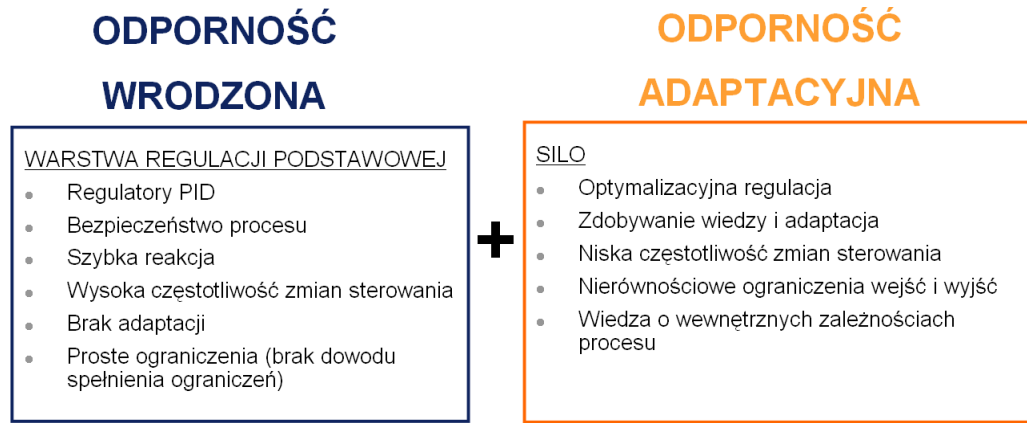
Analizując działanie systemu SILO należy uwzględnić istnienie podstawowej warstwy regulacji i na układ regulacji patrzeć jak na pewną całość. Przy takim założeniu można zastosować analogię do układu odpornościowego polegającą na tym, że podstawowy układ regulacji reprezentuje odporność wrodzoną (patrz rozdział 3), a system SILO reprezentuje odporność adaptacyjną. Tak więc kompletny Sztuczny System Immunologiczny posiadający odporność wrodzoną i adaptacyjną jest reprezentowany przez cały warstwowy układ regulacji złożony z warstwy regulacji bezpośredniej i systemu SILO. Powyższe rozważania reprezentuje rys. 4.2.

Na rys. 4.3 przedstawiono przykład połączenia systemu SILO z systemem DCS. Nie jest to jedyne dopuszczalne rozwiązanie. System SILO nie musi być instalowany na osobnym komputerze. Można też zainstalować SILO na stacji inżynierskiej systemu DCS. Nadzór nad programem SILO sprawuje się z wykorzystaniem graficznego interfejsu użytkownika opartego na technologii WWW. Tak więc dostęp do interfejsu użytkownika systemu SILO jest możliwy ze wszystkich komputerów podpiętych do sieci intranetowej, w której znajduje się komputer z zainstalowanym systemem SILO.

Podczas wdrażania systemu SILO należy:

- zmodyfikować podstawowy układ regulacji w taki sposób aby system SILO mógł





Rysunek 4.2 Wielowarstwowy układ regulacji jako Sztuczny System Immunologiczny.

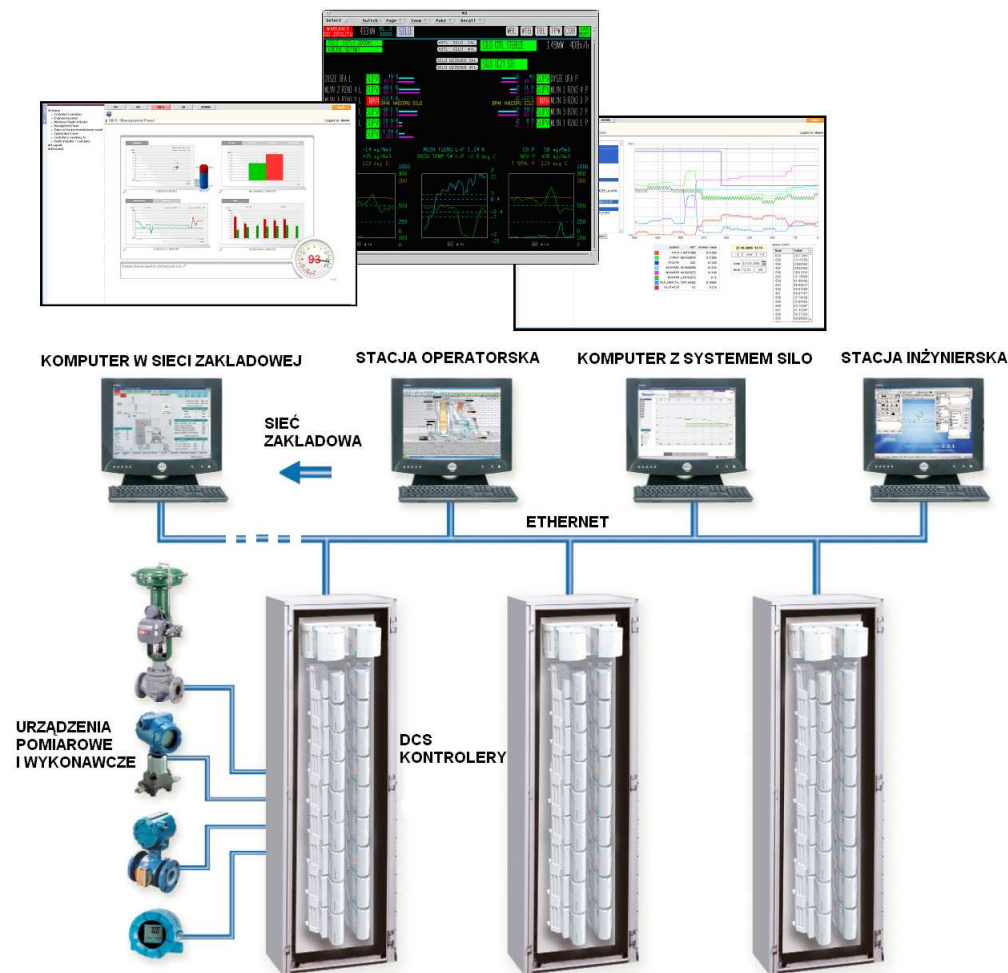
modyfikować sygnały reprezentujące wartości zadane warstwy regulacji bezpośrednio;

- zmodyfikować układ regulacji i grafiki operatorskie w taki sposób aby możliwe było bezpieczne włączenie i wyłączenie modułu optymalizacji SILO, oraz bezpieczne włączenie i wyłączenie poszczególnych urządzeń wykonawczych (lub grup urządzeń wykonawczych) z pod kontroli systemu SILO;
- zmodyfikować układ regulacji i grafiki operatorskie w taki sposób aby umożliwić włącznie i wyłączenie modułu uczenia SILO;
- zmodyfikować układ regulacji w taki sposób aby regulator SILO był w sposób bezpieczny automatycznie wyłączany w sytuacji wykrycie niepoprawnego działania jednego z modułów SILO lub braku komunikacji między systemem DCS i SILO.

Bezpieczne wyłączenie systemu SILO oznacza przejęcie kontroli nad procesem przez operatora lub podstawowy układ regulacji w taki sposób, że zmiana wektora sterowań jest ciągła, wystarczająco wolna i nie powoduje niestabilnej pracy obiektu. Na rys. 4.4 przedstawiono uproszczony schemat logiki włączenia/wyłączenia systemu SILO.

Aby moduł optymalizacji systemu SILO mógł zostać włączony muszą być spełnione następujące warunki:

- co najmniej  $n$  urządzeń sterujących musi być w trybie AUTO. Tryb AUTO oznacza, że kontrolę nad tymi zmiennymi sterującymi sprawuje podstawowy system automatyki. Jeżeli wybrane urządzenie pracuje w trybie MANUAL oznacza to, że



Rysunek 4.3 Optymalizator SIŁO w systemie DCS.

operator ma pełną kontrolę nad działaniem tego urządzenia i nie możliwe jest jego automatyczne nadzorowanie;

- wykrywany jest sygnał o zdefiniowanym przebiegu czasowym, oznaczający gotowość SIŁO do podjęcia pracy;
- spełnione są dodatkowe warunki takie jak na przykład wykrycie nominalnego zakresu pracy obiektu.

Przykład grafiki operatorskiej zaimplementowanej w systemie DCS umożliwiającej zarządzanie systemem SIŁO, oraz urządzeniami będącymi pod nadzorem SIŁO został pokazany na rys. 4.5

System SILO modyfikuje wartości zadane regulatorów warstwy regulacji bezpośredniej. Zakres tych modyfikacji, oraz maksymalna dopuszczalna modyfikacja sterowań w jednym kroku optymalizacji ustalana jest w taki sposób, aby odpowiedzi obiektu na tę modyfikację sygnału sterowania były stabilne. Tak więc system SILO wprowadza do warstwy regulacji bezpośredniej pewne modyfikacje sygnałów sterowania w taki sposób, że po ich wprowadzeniu podstawowy układ sterowania znajduje się w obszarze bezpiecznej pracy, dla którego został zaprojektowany. Na rysunku 4.6 przedstawiono przykład hipotetycznej zależności między zawartością tlenu w spalinach (wejście sterowane) i relatywnym obciążeniu bloku energetycznego (mierzone zakłócenie), zaimplementowanej w układzie regulacji kotła energetycznego. Widać, że układ regulacji podstawowej zmienia wartość zadaną na poziom tlenu w spalinach w zależności od obciążenia bloku. System SILO wdrożony w warstwie optymalizacji modyfikuje wartość zadaną regulatora tlenu. Zakres tych modyfikacji mieści się jednak w granicach obszaru bezpiecznej pracy regulatora.

Na rys. 4.7 w sposób schematyczny przedstawiono sposób wpięcia systemu SILO w warstwę regulacji bezpośredniej. W rozwiązaniu przedstawionym na rys. 4.7 system SILO wystawia poprawkę sterowania dodawaną do sygnału wartości zadanej, generowanego przez podstawowy system sterowania. Gdy system SILO jest wyłączony lub gdy SILO ma wyłączoną możliwość modyfikowania wybranej zmiennej sterującej, wówczas poprawkę sterowania może generować operator. Nie jest to jedyny poprawny schemat wpięcia. Na rysunku 4.8 przedstawiono wpięcie, w którym SILO nie generuje jedynie poprawki wartości zadanej, ale bierze pełną odpowiedzialność za generowanie wartości zadanej dla regulatora warstwy regulacji bezpośredniej. Należy zauważyć, że nawet w tym schemacie wpięcia bierze się pod uwagę wartość zadaną generowaną przez układ regulacji bezpośredniej i wprowadza się ograniczenie polegające na tym, że wartość generowana przez SILO nie może odbiegać od wartości generowanej przez układ regulacji bezpośredniej o więcej niż pewna zdefiniowana wartość.

Przedstawiony na rys. 4.7 i 4.8 regulator warstwy regulacji bezpośredniej ma za zadanie utrzymać zadaną wartość regulowanego sygnału, reprezentującego zmienną sterującą systemu SILO (np.: poziom tlenu w spalinach w przypadku optymalizacji procesu spalania w kotle energetycznym). Sterowanie wystawiane przez regulator może być dalej zmodyfikowane przez inne algorytmy warstwy regulacji bezpośredniej (np: ograniczenia w zależności od specyficznych warunków pracy obiektu). Operator

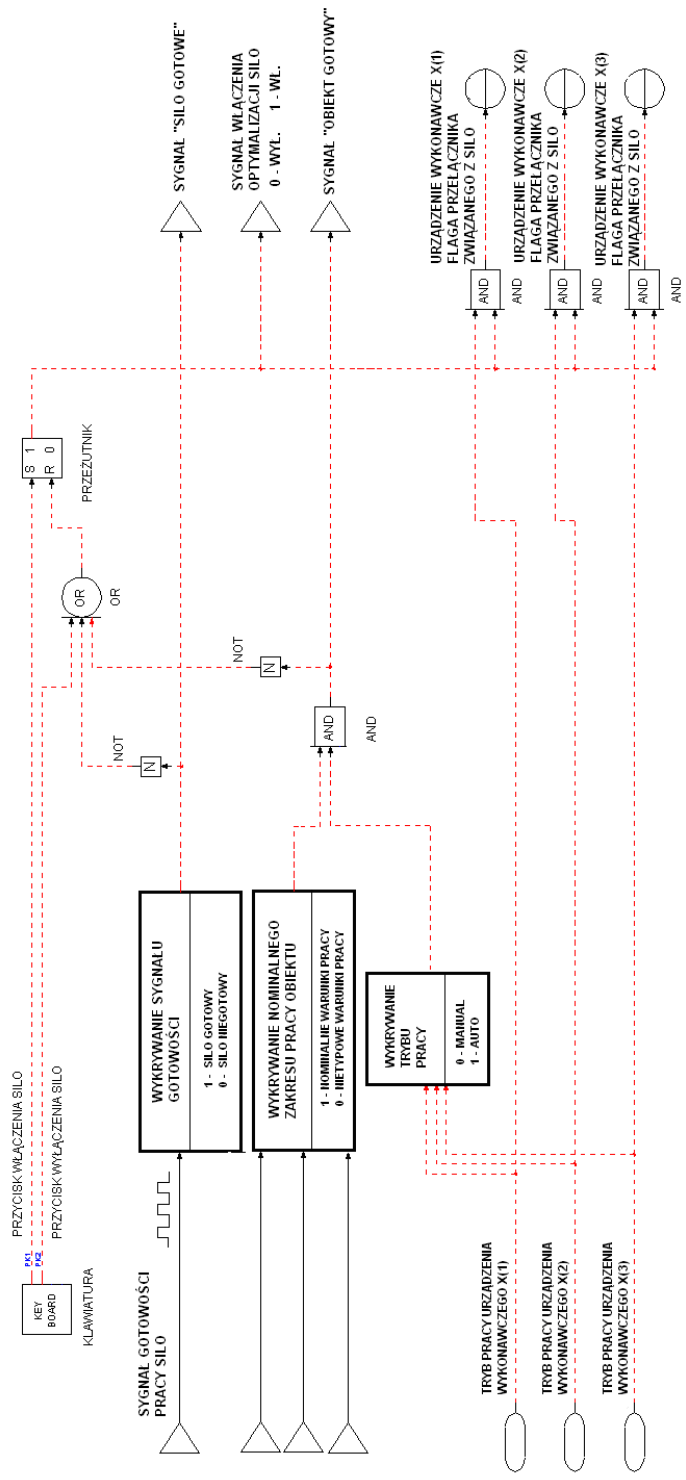
ma też możliwość ręcznego generowania sygnału sterowania (tryb MANUAL), będącego wyjściem regulatora PID. Wówczas algorytm śledzenia zaimplementowany w warstwie regulacji bezpośredniej zapewni, że ponowne załączenie regulatora warstwy regulacji bezpośredniej w tryb AUTO nie spowoduje skoku wartości zadanej i zmiana trybu sterowania będzie płynna.

Na rys. 4.7 i 4.8 wprowadzono rozbitcie wektora sterowań na podwektory. Każdy element wektora  $x$  reprezentuje rekord składający się z czterech elementów. Podział wektora  $x$  na cztery skojarzone podwektory komplikuje nieco koncepcyjne rozważania przedstawione w dalszej części rozprawy. Autor zdecydował się przedstawić ów podział ze względu na sprecyzowanie opisu przedstawionych w rozdziale 8 algorytmów, tak aby czytelnik był w stanie wykorzystać ten opis do dalszego rozwoju prezentowanego rozwiązania. W systemie SILO każdy element wektora  $x$  składa się z następujących podelementów:

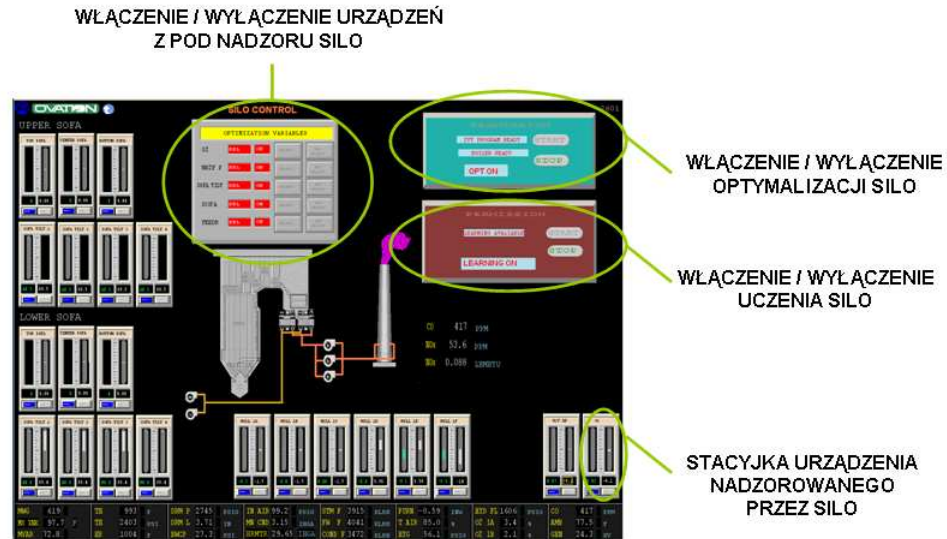
- $x_{stat}^i$  – zmienna przechowująca informacje o tym, czy  $i$ -ty element wektora  $x$  znajduje się pod kontrolą SILO;
- $x_{comp}^i$  – wartość sterowania dla  $i$ -tego elementu, obliczona przez system SILO i wysłana do podstawowego układu regulacji (patrz. rys 4.7 i 4.8);
- $x_{trace}^i$  – wartość śludzona  $i$ -tego elementu wektora  $x$ . W przypadku gdy możliwość sterowania wybranym elementem wektora  $x$  jest wyłączona (np: ze względu na to, że nadzór systemu SILO jest wyłączony) wówczas zmiennej  $x_{comp}^i$  przypisywana jest wartość zmiennej  $x_{trace}^i$ . Ponadto wartość zmiennej  $x_{trace}^i$  jest punktem startowym optymalizacji w każdej z warstw optymalizatora SILO (patrz rozdział 8);
- $x_{real}^i$  - w systemie SILO zmienna ta reprezentuje wartość sprzężenia zwrotnego dla  $i$ -tego elementu wektora  $x$ . W przypadku, gdy SILO oblicza wartość sygnału zadanego dla regulatora warstwy regulacji bezpośredniej (rys. 4.8), zmienna  $x_{real}^i$  reprezentuje zmierzoną wartość regulowanego sygnału. W przypadku jak na rys. 4.7 wartość  $x_{real}^i$  reprezentuje rzeczywistą poprawkę wprowadzoną do sygnału wartości zadanej. Informacja zawarta w zmiennej  $x_{real}^i$  używana jest do oceny stanu procesu w kontekście wskaźnika jakości, oraz wykorzystywana jest przez moduł uczący do zdobywania wiedzy o procesie.

Ogólny schemat przedstawiający dwa rodzaje wpięć, uwzględniający rozbitcie wektora  $x$  na cztery podwektory został pokazany na rys. 4.9. Podział wektora sterowania na cztery podwektory uwzględniany jest przez system SILO w następujący sposób:

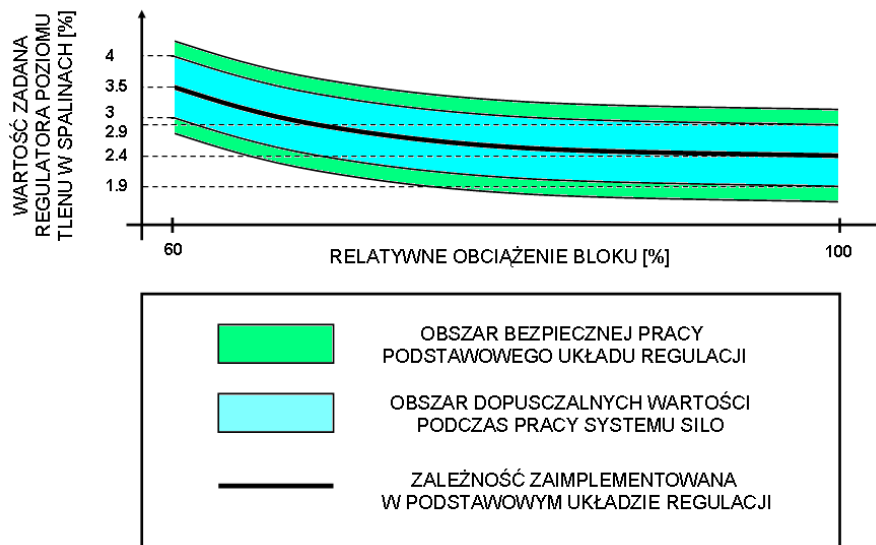
- Moduł uczenia analizuje aktualne i przeszłe wartości elementów wektora  $x_{real}$  (patrz rozdział 7). Limfocyty typu B przechowują więc informacje o przyroście elementów wektora  $x_{real}$ ;
- Podczas definiowania sposobu obliczania stopnia wiązania przeciwciała może być wykorzystana informacja o wartości elementów wektora  $x_{real}$  (patrz rozdział 5);
- W algorytmie optymalizacji, w warstwie optymalizacji na modelu mieszanym lub globalnym, wektor  $x_{trace}$  stanowi punkt startowy (rozwiązanie początkowe) optymalizacji (patrz rozdział 8);
- Algorytm optymalizacji oblicza przyrost sterowania w stosunku do wektora  $x_{trace}$ . Obliczony wektor przyrostów sterowania dodawany jest do wektora  $x_{trace}$ , tworząc wektor  $x_{comp}$ . Wektor  $x_{comp}$  wysyłany jest do warstwy regulacji bezpośredniej (patrz rozdział 8).



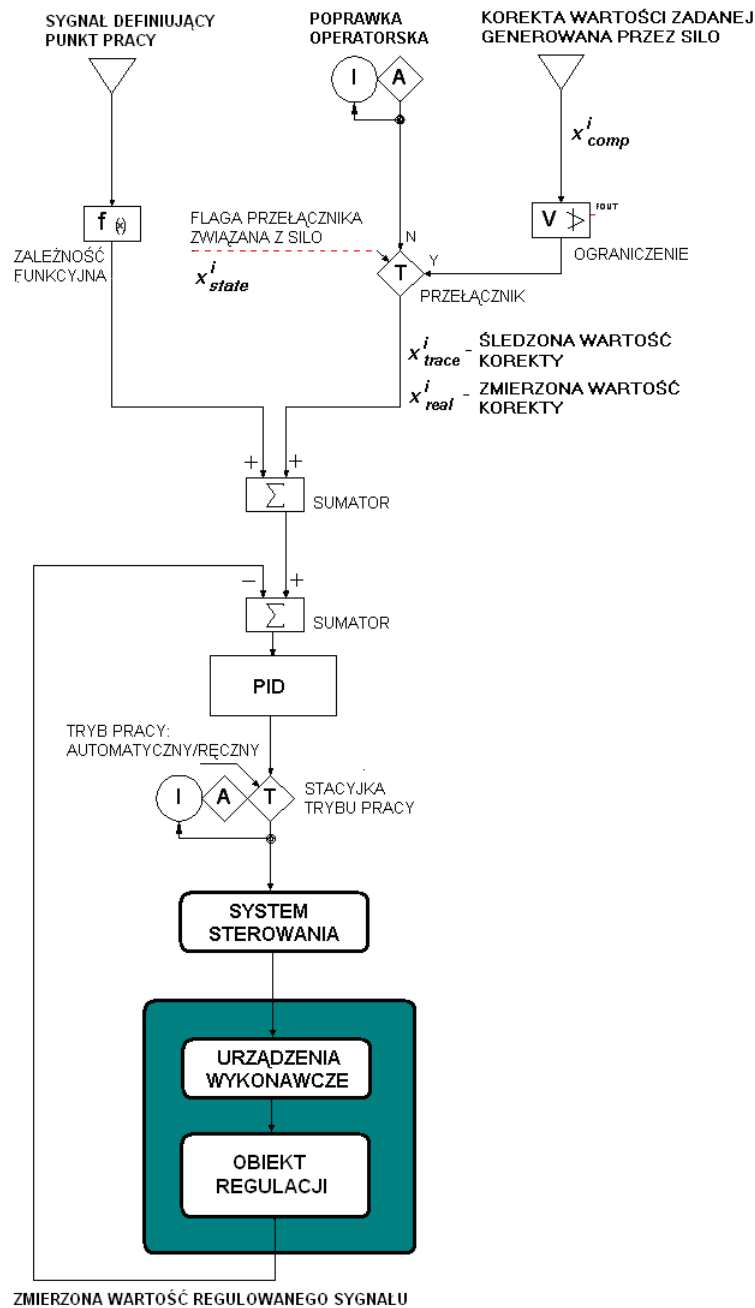
Rysunek 4.4 Uproszczony schemat logiki załączenia modułu optymalizacji systemu SILO.



Rysunek 4.5 Przykład grafiki operatorskiej.

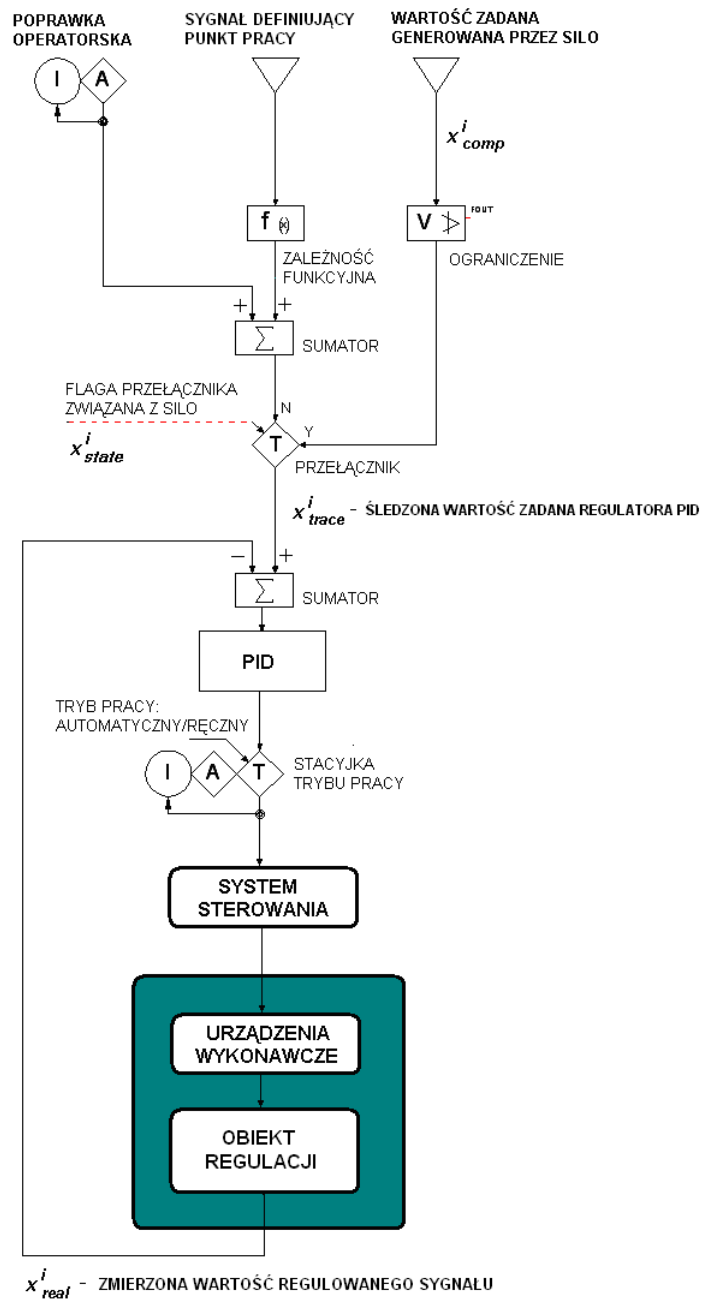


Rysunek 4.6 Bezpieczny obszar pracy układu regulacji na przykładzie hipotetycznej zależności zawartości poziomu tlenu w spalinach od relatywnego obciążenia bloku.

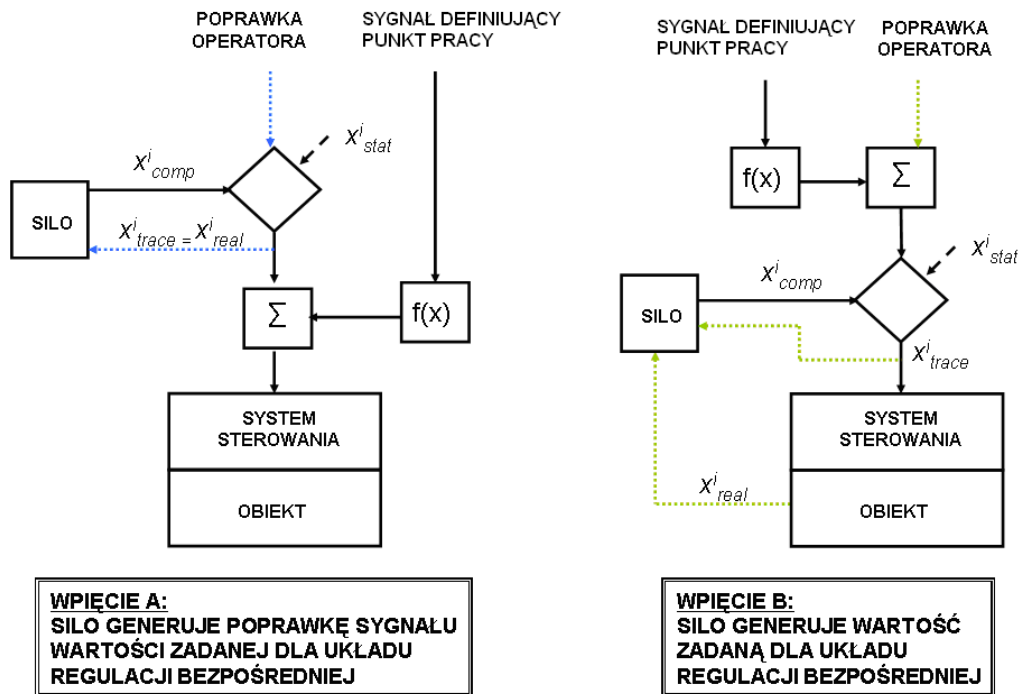


Rysunek 4.7 Wpięcie systemu SIŁO - korekta wartości zadanej.





Rysunek 4.8 Wpięcie systemu SILO - pełna odpowiedzialność za generowanie wartości zadanej.



Rysunek 4.9 Dwa sposoby wykonania wpięć.

# Rozdział 5 Immunologiczna struktura systemu SILO

W rozdziale tym przedstawiono zadanie bieżącej optymalizacji punktu pracy procesu technologicznego w kontekście struktury i mechanizmów układu odpornościowego. Struktura systemu SILO została porównana ze strukturą układu odpornościowego organizmów żywych. Tabela 5.1 pokazuje podobieństwa istniejące między układem odpornościowym i systemem SILO. W kolejnych podrozdziałach szczegółowo omówiono strukturę systemu SILO w kontekście struktury układu odpornościowego organizmów żywych.

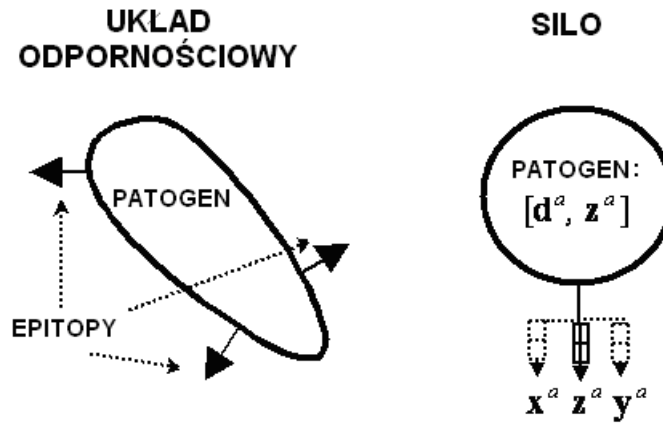
## 5.1 Patogen

W układzie odpornościowym organizmów żywych przeciwciała rozpoznają patogeny dzięki epitopom znajdującym się na powierzchni patogenu. Innymi słowy epitopy prezentują patogen komórkom układu odpornościowego. Epitop to fragment antygeny, który łączy się bezpośrednio z przeciwciałem.

W systemie SILO patogen reprezentuje zakłócenia mierzalne i niemierzalne, które oddziałują na proces technologiczny (rys. 5.1). Patogen prezentowany jest systemowi w postaci aktualnego stanu procesu, który jest definiowany jako trójka  $A = [x^a, y^a, z^a]$ , gdzie  $x^a$  to wektor aktualnych sterowań,  $y^a$  to wektor aktualnych wartości wyjść procesu,  $z^a$  to wektor aktualnych wartości zakłóceń mierzonych. Tak więc trójka  $A = [x^a, y^a, z^a]$  jest epitopem. W przypadku zakłóceń mierzonych wektor  $z$  w sposób jednoznaczny definiuje patogen. Sytuacja jest bardziej skomplikowana w przypadku zakłóceń niemierzalnych lub rzadko mierzonych. O wartości zakłóceń niemierzalnych możemy wnioskować jedynie na podstawie relacji pomiędzy wartościami elementów wektora  $y$ , oraz wartościami elementów wektorów  $x$  i  $z$ . Tak więc chcąc wykrywać

Układ odpornościowy	SILO
patogen	mierzone i niemierzone zakłócenie
przeciwciało: część wiążąca antygen	stan procesu technologicznego zapisany w limfocycie B, który wytworzył przeciwciało
przeciwciało: część efektorowa	zmiana wartości elementów wektora $x$ podawana do obiektu regulacji
limfocyt typu B	obiekt przechowujący informacje o historycznym stanie procesu przed zmianą sterowania i informacje o wpływie tej zmiany sterowania na stan procesu
limfocyt typu $T_h$	algorytm odpowiedzialny za wybór odpowiedniej grupy limfocytów B wykorzystywanych podczas automatycznego tworzenia modelu obiektu regulacji
układ dopełniacza	urządzenia wykonawcze realizujące instrukcje SILO
stan zdrowia organizmu	odwrotność wartości optymalizowanego wskaźnika jakości

Tabela 5.1 Struktura układu odpornościowego i systemu SILO.



Rysunek 5.1 Reprezentacja patogenu.

obecność niemierzalnych zakłóceń konieczne jest posiadanie wiedzy o aktualnym stanie procesu.

Widać wyraźnie, że chcąc uwzględnić działanie zakłóceń niemierzalnych prezentacja patogenu w systemie SILO musi być zdefiniowana poprzez aktualny stan procesu  $A = [x^a, y^a, z^a]$ . Przyjęcie takiego założenia znacznie komplikuje proces rozpoznawania patogenu przez przeciwciała. W jednej z pierwszych wersji SILO [113] wnioskowano o obecności niemierzalnego zakłócenia na podstawie różnicy między aktualnym stanem wektora  $y$  i wyjściem modelu matematycznego  $\hat{y} = f(x, z)$ . Eksperymenty przeprowadzone w jednej z polskich elektrowni wykazały jednak, że taki mechanizm komplikuje niepotrzebnie algorytm optymalizacji i pogarsza zdolność SILO do generalizacji wiedzy o procesie. Na brak skuteczności powyższego mechanizmu składają się następujące przyczyny:

- szумы pomiarowe;
- znaczne oscylacje sygnałów reprezentujących optymalizowane wyjścia wynikające z niedostatecznego zestrojenia podstawowego układu regulacji;
- gwałtowne chwilowe zmiany sygnałów reprezentujących optymalizowane wyjścia występujące w trakcie zmiany sygnałów reprezentujących zakłócenia, wynikające z niedostatecznego zestrojenia podstawowego układu regulacji;
- awarie urządzeń wykonawczych.

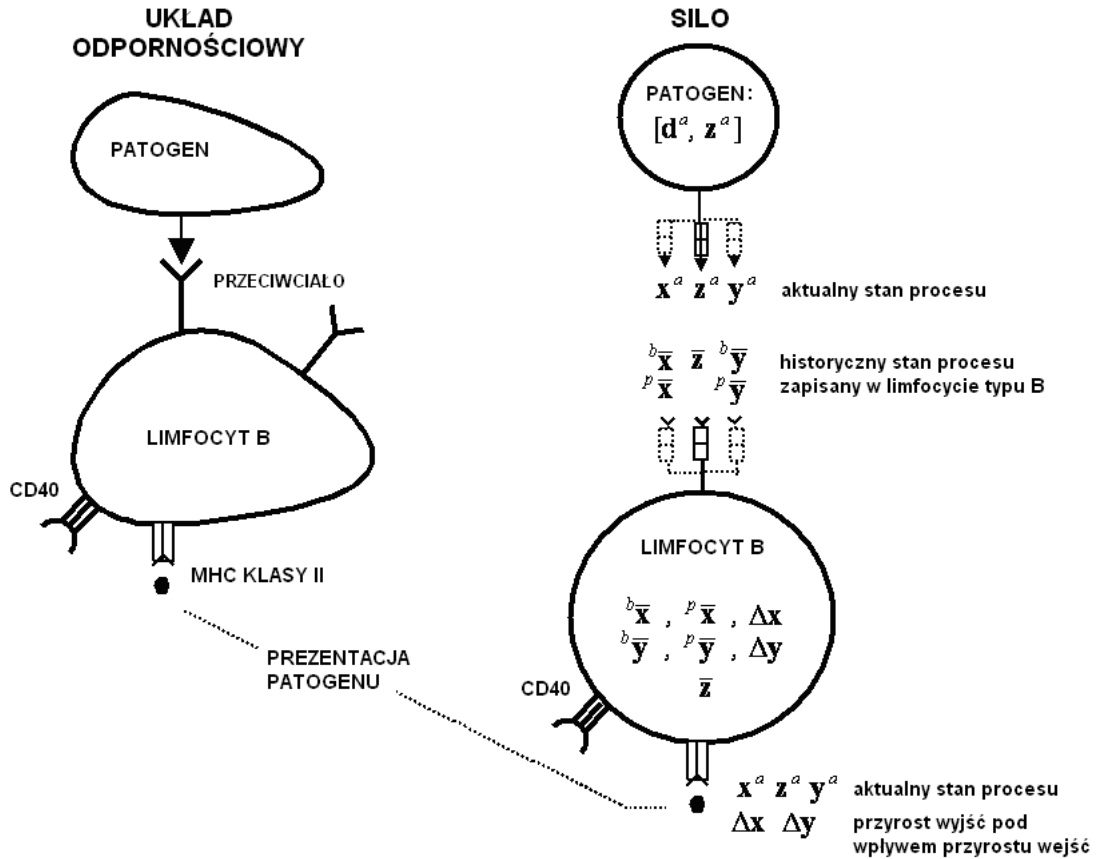
Powyższe przyczyny powodowały, że algorytm rozpoznawania patogenów, błędnie interpretował niektóre sytuacje, jako objaw działania niemierzalnego zakłócenia. Mechanizm opisany w [113] powodował, że wiedza zdobyta przez SILO była zbyt silnie dopasowana do szumów pomiarowych i chwilowych zmian stanu procesu, przez co traciła cechę uogólnienia. Tak więc aby zapewnić większą generalizację wiedzy o procesie, zrezygnowano z mechanizmu wnioskowania o niemierzalnym zakłóceniu na podstawie różnicy między aktualnym stanem procesu, a wyjściem modelu matematycznego. Więcej na temat problemu nadmiernego dopasowania do danych i generalizacji wiedzy można znaleźć w [109, 108].

Praktyczne eksperymenty przeprowadzone w jednej z polskich elektrowni pokazały, że w przypadku optymalizacji procesu spalania w kotle energetycznym próby wnioskowania o niemierzalnych zakłóceniach, prowadziły do pogorszenia generalizacji wiedzy o procesie i wynikającym z tego zmniejszeniu efektywności optymalizatora SILO. Dlatego też, we wszystkich dotychczasowych implementacjach SILO (patrz dodatek B) autor ograniczył się do rozpoznawania jedynie mierzonych zakłóceń. W takim przypadku patogen reprezentuje jedynie mierzone zakłócenie i jest bezpośrednio definiowany przez wektor  $z$ . Należy jednak pamiętać, że SILO jest optymalizatorem ogólnego zastosowania. Zważywszy na to postanowiono, że w ogólnym przypadku istnieje możliwość rozpoznawania niemierzalnych zakłóceń na podstawie aktualnego stanu procesu. Tak więc w ogólnym przypadku epitopy, dzięki którym możliwe jest rozpoznanie patogenu, reprezentują aktualny stan procesu.

Przedstawiona w tym podrozdziale struktura patogenu w systemie SILO jest podobna do idei, która została zaprezentowana przez Krishnakumar i Neidhoefer w [18, 57, 56, 55]. Krishnakumar i Neidhoefer również traktowali zakłócenie oddziałujące na system jako patogen.

## 5.2 Limfocyt typu B i $T_h$

W układzie odpornościowym organizmów żywych limfocyty B produkują przeciwciała i biorą udział w procesie tworzenia pamięci immunologicznej. Po wykryciu antygeny przez przeciwciała, antygen jest prezentowany na powierzchni limfocytu w kontekście cząsteczki MHC klasy II. Jeżeli limfocyt  $T_h$  rozpozna prezentowany antygen jako intruza atakującego organizm, wówczas aktywuje limfocyt B. Powoduje



Rysunek 5.2 Limfocyt typu B.

to intensywną proliferację i różnicowanie pobudzonego limfocyty B (proces selekcji klonalnej) [93, 63].

W systemie SILO limfocyt B prezentuje historyczny stan procesu zmierzony przed i po zmianie sterowania. Każda para *stan procesu przed zmianą sterowania* i *statyczna odpowiedź obiektu na zmianę sterowania* reprezentuje jeden limfocyt typu B. Ponadto limfocyt typu B reprezentuje tylko takie historyczne stany procesu, w których zakłócenia oddziałujące na proces były stałe z dokładnością do pewnego przedziału (patrz rozdział 7). Formalna definicja  $k$ -tego limfocyty typu B jest następująca:

$$L_k = [{}^b\bar{x}^k, {}^p\bar{x}^k, {}^b\bar{y}^k, {}^p\bar{y}^k, \bar{z}^k],$$

gdzie:

${}^b\bar{x}^k$  – wektor średnich wartości sygnałów sterujących przed zmianą sterowania,

${}^p\bar{x}^k$  – wektor średnich wartości sygnałów sterujących po zmianie sterowania,

${}^b\bar{y}^k$  – wektor średnich wartości sygnałów wyjściowych przed zmianą sterowania,

${}^p\bar{y}^k$  – wektor średnich wartości sygnałów wyjściowych po zmianie sterowania,

$\bar{z}^k$  – wektor średnich wartości sygnałów zakłócenia.

Na podstawie informacji zawartych w limfocycie B można obliczyć zmianę wartości optymalizowanych wyjść procesu pod wpływem zmiany wartości sygnałów sterujących. Znajomość statycznej zależności przyrostów wartości optymalizowanych wyjść procesu pod wpływem przyrostu zmiennych sterujących jest wykorzystywana podczas konstruowania modeli liniowych optymalizowanego procesu (patrz rozdział 8). W dalszych rozważaniach autor będzie posługiwał się następującymi oznaczeniami:

$$\Delta x^k = {}^p\bar{x}^k - {}^b\bar{x}^k,$$

$$\Delta y^k = {}^p\bar{y}^k - {}^b\bar{y}^k.$$

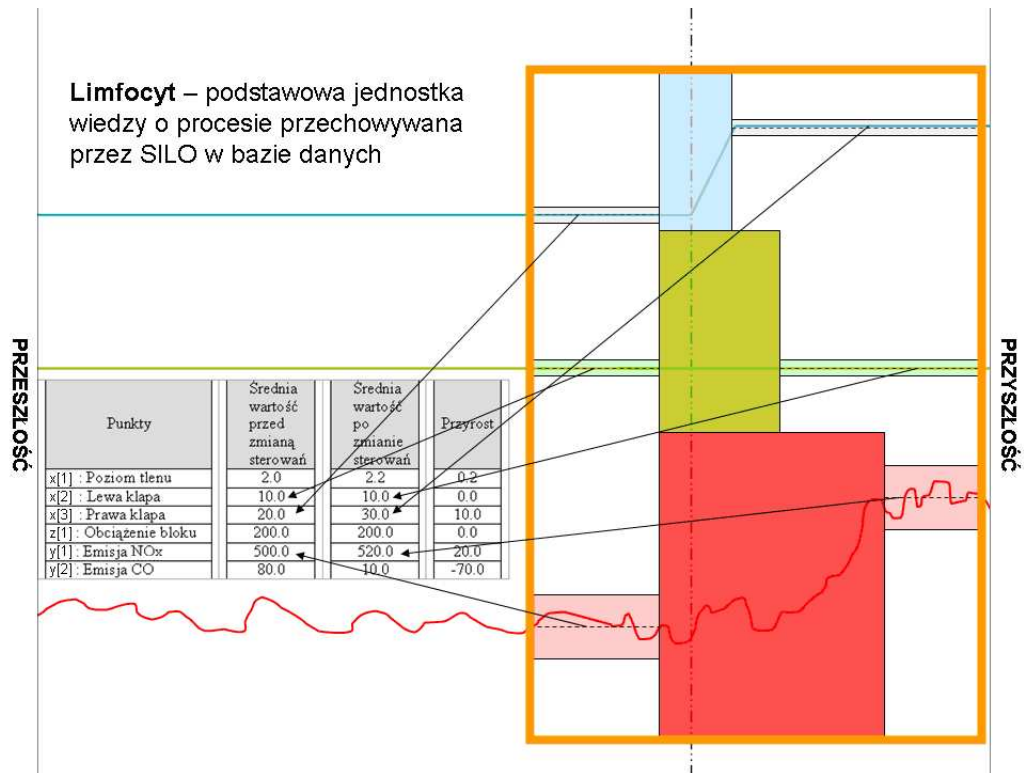
Limfocyty typu B są przechowywane w pamięci immunologicznej stanowiącej część bazy danych systemu SIŁO. Każdy limfocyt typu B reprezentuje elementarny kwant informacji o optymalizowanym procesie. W tabeli 5.2 pokazano przykładowy rekord reprezentujący limfocyt typu B dla uproszczonego zadania optymalizacji procesu spalania.

Tabela 5.2 Przykład limfocytu

Punkty	Średnia wartość przed zmianą sterowań	Średnia wartość po zmianie sterowań	Przyrost
$x_1$ : Poziom tlenu	2.0	2.2	0.2
$x_2$ : Lewa kłapa	10.0	10.0	0.0
$x_3$ : Prawa kłapa	20.0	30.0	10.0
$z_1$ : Obciążenie bloku	200.0	200.0	0.0
$y_1$ : Emisja $NO_x$	500.0	520.0	20.0
$y_2$ : Emisja $CO$	80.0	10.0	-70.0

Przedstawiony w tabeli 5.2 rekord został stworzony na podstawie zmierzonych





Rysunek 5.3 Okno czasowe reprezentujące limfocyt.

wartości punktów procesowych (będących elementami wektorów  $x$ ,  $y$  i  $z$ ) ograniczonych do pewnego przedziału czasowego. Macierz zawierającą zmierzone wartości elementów wektora  $x$ ,  $y$  i  $z$  w kolejnych chwilach czasowych, będziemy dalej nazywać *oknem czasowym*.

**Definicja 5.2.1** *Oknem czasowym o długości  $n$  jest macierz*

$$M = [[x, y, z]_k^t, \dots, [x, y, z]_{k+n-1}^t]$$

Na rys. 5.3 pokazano okno czasowe ograniczone do dwóch elementów wektora  $x$  i jednego elementu wektora  $y$ . Proces przekształcenia macierzy  $M$  reprezentującej okno czasowe w limfocyt typu B polega na obliczeniu:

- średnich wartości sygnałów sterowania przed zmianą sterowania;
- średnich wartości sygnałów sterowania po zmianie sterowania;

- średnich wartości optymalizowanych wyjść procesu przed zmianą sterowania;
- średnich wartości optymalizowanych wyjść procesu po zmianie sterowania i ustaleniu się sygnałów wyjściowych;
- średnich wartości sygnałów reprezentujących zmierzone zakłócenia, przy założeniu że okres uśredniania obejmuje całą długość okna czasowego.

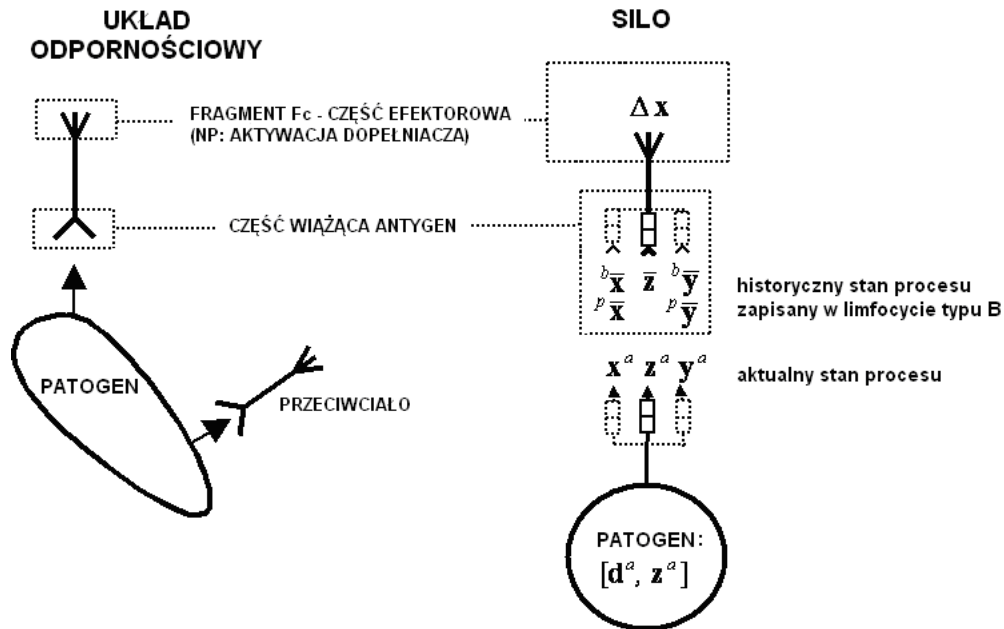
Limfocyty typu B są tworzone tylko na podstawie takich okien czasowych, w których zakłócenia oddziałujące na proces są stałe (z dokładnością do pewnego przedziału) na całej długości okna czasowego. Więcej informacji o sposobie przekształcania okna czasowego do postaci limfocytu typu B można znaleźć w rozdziale 7.

Zadaniem limfocytu  $T_h$  jest aktywowanie odpowiedniej grupy limfocytów B. W systemie SILO funkcję limfocytu  $T_h$  spełnia algorytm obliczający stopień powinowactwa przeciwciała znajdującego się na powierzchni limfocytu B i patogenu (patrz rozdział 5.3). Informacja znajdująca się w aktywowanych limfocytach B jest używana do budowy statycznych linowych modeli optymalizowanego procesu w sąsiedztwie aktualnego punktu pracy.

### 5.3 Przeciwciało

Przeciwciała wytwarzane są przez limfocyty typu B. Zadaniem przeciwciała jest związanie antygeny, znajdującego się na powierzchni patogenu. Każde przeciwciało jest w stanie rozpoznawać tylko określony rodzaj epitopów. Przeciwciało złożone jest z części wiążącej antygen i z części efektorowej [63]. W przypadku systemu SILO część efektorowa przeciwciała to obliczona przez algorytm optymalizacji zmiana wektora sterowania, która minimalizuje wskaźnik jakości (patrz rozdział 8). Tak więc zakłada się, że podanie do obiektu nowego wektora sterowań (przeciwciało) wyeliminuje negatywne skutki działania zakłócenia (patogenu). Powyższe rozumowanie jest podobne do idei zaproponowanej przez Fukuda w [18, 34]. Fukuda traktował wektor reprezentujący najlepsze rozwiązanie jako przeciwciało.

Znanych jest wiele algorytmów liczenia siły wiązania antygeny przez przeciwciało. Należy pamiętać, że miara użyta do obliczenia mocy wiązania zależy od przyjętej struktury limfocytu [16]. W przypadku problemu optymalizacji najczęściej przyjmuje się, że siła wiązania jest liczona na podstawie wartości optymalizowanego wskaźnika



Rysunek 5.4 Przeciwciało.

jakości [111]. W systemie SILO przyjęto inne rozwiązanie. Założono, że przeciwciało wiąże antygen wtedy i tylko wtedy, gdy aktualny stan procesu jest podobny do historycznego stanu procesu, zapisanego w limfocycie B, który wytworzył przeciwciało. Zbiór analizowanych punktów procesowych może zostać ograniczony jedynie do punktów reprezentujących mierzone zakłócenie. W przypadku gdy charakterystyki poszczególnych punktów procesowych są silnie nieliniowe istnieje możliwość porównywania także aktualnych (antygen) i historycznych (przeciwciało) wartości punktów z wektora  $x$  oraz  $y$ .

**Przykład 5.3.1** *W przypadku procesu spalania w kotle energetycznym charakterystyka sygnału emisji CO (optymalizowane wyjście procesu) jest nieliniowa. Gdy poziom emisji CO jest niski, reakcja tego sygnału na zmianę sterowania charakteryzuje się mniejszym wzmocnieniem, w porównaniu do sytuacji, gdy średni poziom emisji CO jest wysoki. Tak więc, w niektórych przypadkach uzasadnione jest porównywanie aktualnej wartości emisji CO ze średnią wartością emisji CO zapisaną w limfocycie B, do ustalenia siły wiązania antygeny i przeciwciała.*

Wybór porównywanych elementów wektorów  $x$ ,  $y$ ,  $z$  definiuje podział przestrzeni zdefiniowanej przez wartości elementów wektorów  $x$ ,  $y$ ,  $z$  na podprzestrzenie, w

których aproksymacja procesu modelem liniowym jest wystarczająco dokładna. Wyboru elementów wektorów  $x$ ,  $y$ ,  $z$ , które będą podlegać porównaniu, dokonuje ekspert wdrażający system SIŁO.

Należy zauważyć, że jeżeli aktualne, zmierzone wartości wektorów  $x$ ,  $y$  i  $z$  są podobne do wektorów  $x$ ,  $y$  i  $z$  zapisanych w limfocycie, to również aktualny wektor  $d$  (wektor nieuwzględnianych i niemierzalnych zakłóceń) jest podobny do wektora  $d$ , który oddziaływał na proces w przeszłości. Istnieje proste wyjaśnienie tej zależności. Jeżeli wektory  $d$  są wyraźnie różne i wektory te istotnie wpływają na wyjścia procesu, to odpowiedź procesu (wektor  $y$ ) na takie samo pobudzenie (wektory  $x$  i  $z$ ) będzie się różnić. Tak więc informacja o niemierzalnych lub rzadko mierzonych zakłóceniami może być niejawnie uwzględniana przez system SIŁO. Praktyczne eksperymenty pokazują jednak, że w przypadku optymalizacji procesu spalania próby wnioszkowania o niemierzalnych zakłóceniami, prowadzą nieuchronnie do pogorszenia generalizacji wiedzy o procesie i wynikającym z tego zmniejszeniu efektywności optymalizatora SIŁO (patrz rozdział 5.1).

Do obliczenia stopnia powinowactwa antygeny  $A$  i  $k$ -tego limfocytu  $B$  zawierającego przeciwciała używana jest następująca funkcja:

$$\begin{aligned} \mu(L_k, A) = & \left( \prod_{i=1}^{nx} g_i^{x^b} ({}^b\bar{x}_i^k, x_i^a) \right) \times \left( \prod_{i=1}^{nx} g_i^{x^p} ({}^p\bar{x}_i^k, x_i^a) \right) \times \left( \prod_{i=1}^{ny} g_i^{y^b} ({}^b\bar{y}_i^k, y_i^a) \right) \times \\ & \times \left( \prod_{i=1}^{ny} g_i^{y^p} ({}^p\bar{y}_i^k, y_i^a) \right) \times \left( \prod_{i=1}^{nz} g_i^z ({}^z\bar{z}_i^k, z_i^a) \right) \end{aligned}$$

gdzie  $\forall_{x_1, x_2 \in \mathfrak{R}} g(x_1, x_2) \in \{0, 1\}$ . Poniżej przedstawiono przykłady prostych funkcji używanych do obliczenia stopnia dopasowania

### Przykład 5.3.2

$$g(x_1, x_2) = \begin{cases} 0 & \text{jeżeli } |x_1 - x_2| > \varepsilon \\ 1 & \text{jeżeli } |x_1 - x_2| \leq \varepsilon \end{cases}$$

### Przykład 5.3.3

$$g(x_1, x_2) = \begin{cases} 1 & \text{jeżeli } x_1 < 10 \wedge x_2 < 10 \\ 1 & \text{jeżeli } x_1 \geq 10 \wedge x_2 \geq 10 \\ 0 & \text{w p.p.} \end{cases}$$

**Przykład 5.3.4**

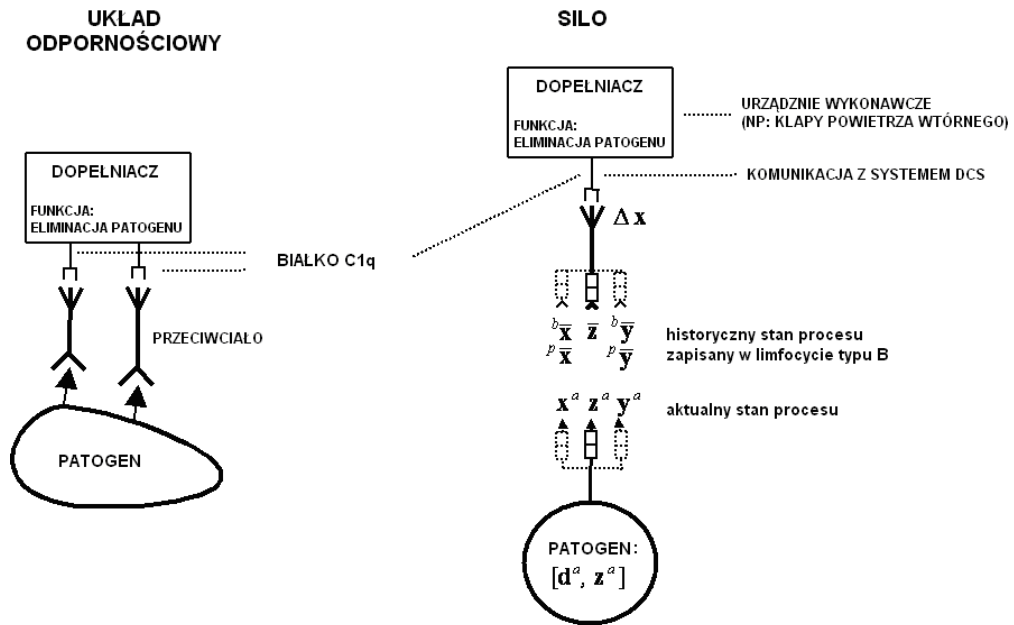
$$g(x_1, x_2) = 1$$

W ostatnim przykładzie przyjęta postać funkcji  $g(x_1, x_2)$  oznacza, że warunek dopasowania jest zawsze spełniony dla dowolnych wartości  $x_1$  i  $x_2$ .

W systemie SILO stopień powinowactwa przyjmuje wartości ze zbioru  $\{0, 1\}$ . Wartość zerowa oznacza, że przeciwciało nie wiąże antygeny, zatem limfocyt typu B, który wytworzył przeciwciało nie reprezentuje punktu pracy procesu, który jest podobny do aktualnego punktu pracy. Tak więc użycie wiedzy zawartej w tym limfocycie do budowy liniowego modelu procesu w okolicy aktualnego punktu pracy jest nieuzasadnione. Jeżeli  $\mu(L_k, A) = 1$ , oznacza to, że limfocyt typu B reprezentuje podobny punkt pracy procesu do aktualnego i wiedza zawarta w tym limfocycie może być użyta do budowy liniowego modelu matematycznego procesu w okolicy aktualnego punktu pracy (patrz rozdział 8).

## 5.4 Układ dopełniacza

Zadaniem przeciwciała jest związanie antygeny. Gdy przeciwciało zwiąże antygen, wówczas część efektorowa przeciwciała aktywuje układ dopełniacza. Działanie układu dopełniacza ma charakter cytotoksyczny. Jego zadaniem jest liza patogenu [93]. W przypadku systemu SILO część efektorowa przeciwciała składa się z urządzeń wykonawczych, które realizują instrukcje SILO.

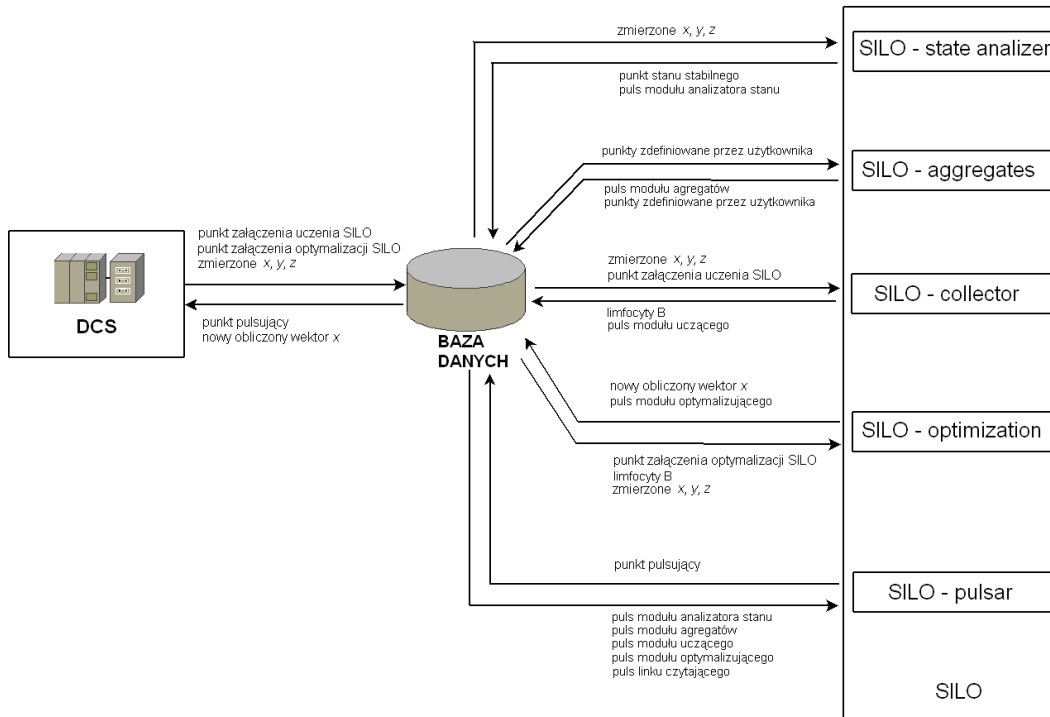


Rysunek 5.5 Układ dopełniacza.

## Rozdział 6 Ogólna zasada działania

System SILO składa się z pięciu podstawowych modułów. Poszczególne moduły zrealizowane są jako niezależne procesy. Komunikacja między modułami odbywa się przy pomocy specjalnych punktów znajdujących się w bazie danych, reprezentujących rzeczywiste lub wirtualne sygnały. Wymiana informacji z systemem DCS odbywa się za pośrednictwem bazy danych (rys. 6.1). Poszczególne moduły piszą i czytają z bazy danych wartości punktów procesowych, reprezentujących sygnały związane z obiektem regulacji. Ponadto istnieją dwa dodatkowe procesy odpowiedzialne za przesyłanie informacji z systemu DCS do bazy danych, oraz z bazy danych do systemu DCS.

Dwa główne moduły SILO to moduł uczenia i moduł optymalizacji. Zadaniem modułu uczącego jest analiza punktów procesowych, będących elementami wektora  $x$ ,  $y$ ,  $z$  i identyfikacja okien czasowych *zawierających* limfocyty typu B (patrz rozdział 7). Po wykryciu okna czasowego zawierającego limfocyt typu B moduł uczący przekształca okno czasowe do postaci limfocytu i zapisuje powstały limfocyt w bazie danych. Jednym z podstawowych kryteriów jakie musi spełnić okno czasowe, aby można było o nim powiedzieć, że zawiera w sobie limfocyt typu B, jest konieczność wystąpienia zmiany wartości chociaż jednego sygnału sterującego. W trakcie normalnej pracy obiektu przez cały czas mamy do czynienia ze zmianami sygnałów sterujących. Proces tworzenia nowych limfocytów jest więc procesem ciągłym. Nieustanne uczenie się procesu jest jedną z podstawowych cech systemu SILO. Poprzez wykrywanie zmian sterowania i zapamiętywanie reakcji obiektu na te zmiany, system SILO na bieżąco uaktualnia swoją wiedzę o obiekcie. Ta cecha sprawia, że prezentowane rozwiązanie jest w stanie adaptować się do zmiennych warunków pracy. Jest to szczególnie ważne w przypadku procesów technologicznych, których charakterystyki zmieniają się wraz z upływem czasu. Zmiany charakterystyk wynikają ze zużycia urządzeń wykonawczych, modernizacji obiektu, istotnych zmian właściwości chemicznych używanych



Rysunek 6.1 Moduły systemu SILO.

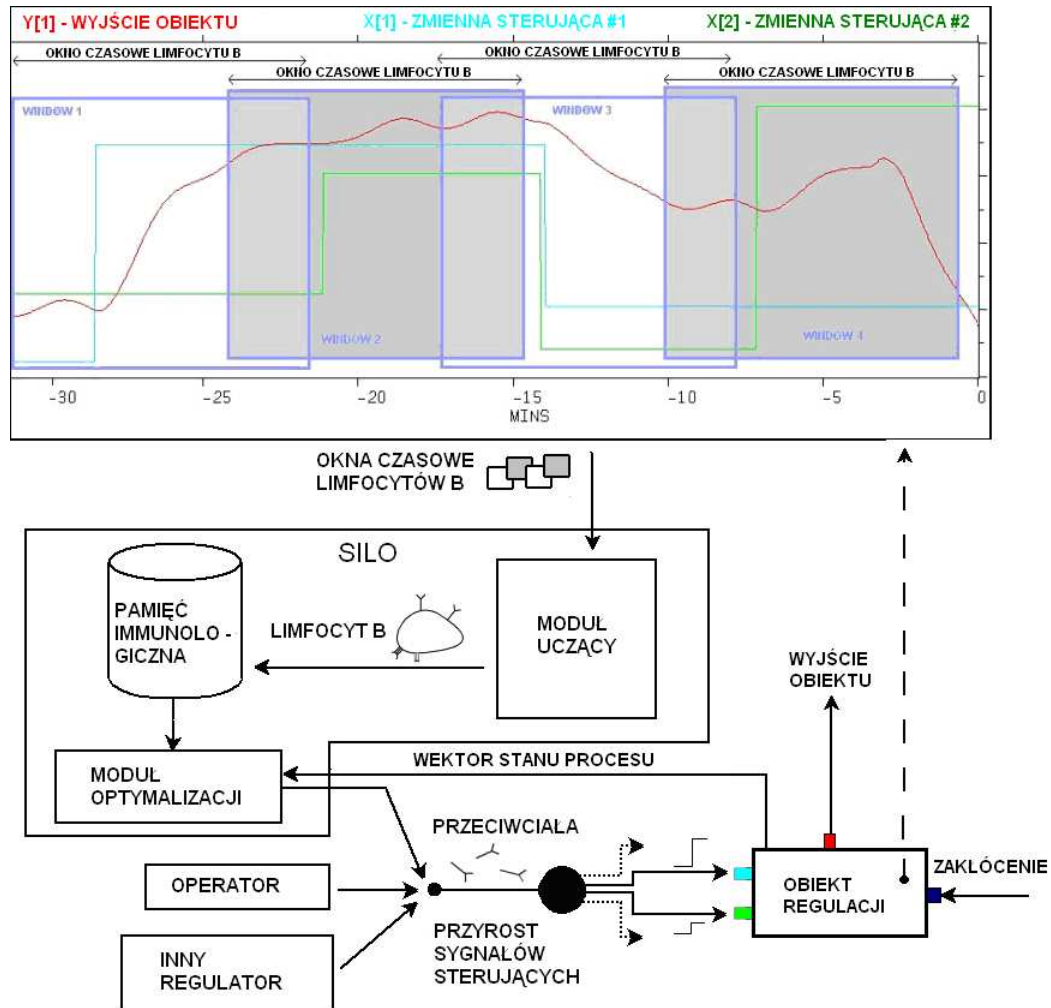
składników, zmiennych warunków zewnętrznych (np: temperatura powietrza) i zmian w podstawowych strukturach regulacji.

Moduł uczenia jest w pełni niezależny od modułu optymalizacji. Moduł uczenia jest w stanie zidentyfikować i zapisać w bazie danych (w pamięci immunologicznej) limfocyty typu B powstałe w wyniku:

- zmiany wektora sterowań dokonanej przez moduł optymalizacji SILO;
- zmiany wektora sterowań dokonanej przez operatora procesu;
- zmiany wektora sterowań dokonanej przez inny regulator;
- analizy pliku zawierającego historyczne wartości punktów procesowych (uczenie wsadowe).

Moduł optymalizacji realizuje bieżącą optymalizację punktu pracy. Na podstawie aktualnej wartości wskaźnika jakości, oraz na podstawie limfocytów znajdujących się w pamięci immunologicznej, moduł optymalizacji oblicza optymalną zmianę wektora sterowań. Wartość wskaźnika jakości zależy od wartości elementów wektorów  $x$  i  $y$





Rysunek 6.2 Ogólna zasada działania systemu SILO.

(patrz rozdział 8). Moduł optymalizacji składa się z trzech warstw. Każda z warstw reprezentuje inny algorytm optymalizacji. W trakcie normalnej pracy obiektu moduł optymalizacji automatycznie przełącza się pomiędzy warstwami. Używanie trzech różnych algorytmów optymalizacji wynika z konieczności:

- eksploracji i eksploatacji przestrzeni rozwiązań;
- skutecznego reagowania na nowy, nieznany patogen (pierwotna odpowiedź immunologiczna);

Moduł optymalizacji	Moduł uczenia	Opis
włączony	włączony	normalna praca obiektu
wyłączony	włączony	moduł uczenia uczy się procesu na podstawie zmian sygnału sterującego, spowodowanych przez operatora lub inny algorytm sterowania
włączony	wyłączony	sytuacja panująca na obiekcie nie pozwala na naukę, ale w dalszym ciągu możliwa jest optymalizacja procesu (przykłady: kalibracja sygnałów pomiarowych, testy urządzeń wykonawczych)
wyłączony	wyłączony	sytuacja na obiekcie nie pozwala na naukę i optymalizację procesu przy użyciu optymalizatora SILO. Przykład: rozruch obiektu, awaria aparatury pomiarowej

Tabela 6.1 Niezależna praca modułu uczenia i modułu optymalizacji.

- efektywnego wykorzystania posiadanej wiedzy o procesie w przypadku walki z patogenem podobnym do tego, który w przeszłości zaatakował już system (wtórna reakcja immunologiczna);
- zapewnienia dobrego uwarunkowania zadania identyfikacji modelu obiektu regulacji (patrz rozdział 8).

Okres optymalizacji jest zdefiniowany jako czas jaki upływa między kolejnymi zmianami wektora sterowań  $x$ . Jest on nie mniejszy niż czas potrzebny na ustalenie się odpowiedzi obiektu, będącej reakcją na zmianę wektora sterowań.

Moduł optymalizacji i moduł uczenia są w pełni niezależne. Tabela 6.1 pokazuje możliwe konfiguracje pracy obydwu modułów. Niezależna praca tych modułów zapewnia brak konieczności przeprowadzania osobnych automatycznych testów mających na celu jedynie zwiększenie stanu wiedzy o procesie, nie uwzględniających celów optymalizacji.

W systemie SILO można wyróżnić jeszcze trzy inne moduły:



Rysunek 6.3 Sygnał informujący o poprawnym działaniu wszystkich modułów SILO.

1. Moduł analizatora stanu – moduł ten na podstawie zdefiniowanych przez użytkownika warunków sprawdza, czy stan procesu jest ustalony. Informacja ta wykorzystywana jest przez moduł optymalizatora do podjęcia decyzji o zmianie warstwy optymalizacji. Jeżeli stan procesu nie jest ustalony, nie możliwe jest przejście do warstwy optymalizacji stochastycznej (patrz rozdział 8);
2. Moduł agregatów – moduł ten umożliwia zaimplementowanie algorytmów przetwarzających sygnały, reprezentowane przez punkty znajdujące się w bazie danych. Potrzeba przetworzenia punktów procesowych może wynikać z konieczności przystosowania obiektu regulacji, do współpracy z SILO. Przy pomocy tego modułu tworzony jest wirtualny obraz obiektu. W szczególności w module agregatów dokonywane jest uśrednianie, filtracja i estymacja sygnałów, składających się na wektory  $x$ ,  $y$  i  $z$ ;
3. Moduł pulsowania – zadaniem tego modułu jest sprawdzanie, czy komunikacja między systemem DCS i bazą danych, oraz wszystkie moduły wchodzące w skład programu SILO działają poprawnie. Jeżeli moduł nie wykryje żadnych nieprawidłowości, wówczas do systemu DCS wysyłany jest (za pośrednictwem bazy danych) sygnał, którego wartość zmienia się cyklicznie przyjmując jeden z dwóch możliwych poziomów (patrz rys. 6.3).

## Rozdział 7 Moduł uczenia

System SILO to rozwiązanie oparte na bazie wiedzy. Baza ta jest na bieżąco uaktualniana, dzięki czemu SILO jest w stanie adaptować się do zmian charakterystyki statycznej obiektu regulacji. Każdy limfocyt typu B zawiera kwant wiedzy o optymalizowanym procesie. Wiedza ta wykorzystywana jest przez algorytm optymalizacji do obliczenia optymalnych zmian wektora sterowań. Zadaniem modułu uczenia SILO jest gromadzenie wiedzy o procesie. Nauka statycznych charakterystyk procesu odbywa się poprzez analizę historycznych wartości punktów procesowych. Można wyróżnić cztery podstawowe wymagania stawiane modułowi uczenia:

1. Wiedza o procesie musi być uaktualniana możliwie często, tak aby zapewnić jak najszybszą adaptację do nowych warunków pracy;
2. Wiedza o procesie zgromadzona w limfocytach typu B powinna jak najdokładniej odzwierciedlać statyczne zależności istniejące między przyrostami elementów wektora sterowań ( $\Delta x$ ) i przyrostami elementów wektora optymalizowanych wyjść ( $\Delta y$ ). Dlatego też limfocyty typu B powinny reprezentować takie sytuacje, w których zmiany zakłóceń oddziałujących na proces są jak najmniejsze;
3. Możliwe jest gromadzenie wiedzy przy każdej dopuszczalnej konfiguracji elementów wektora  $z$ .
4. Moduł uczenia musi wykrywać sytuacje niereprezentatywne, które nie powinny być analizowane w celu znalezienia limfocytu typu B (np: kalibracja sygnałów pomiarowców, awarie sygnałów pomiarowych, testy urządzeń wykonawczych, nietypowe warunki pracy itp.)

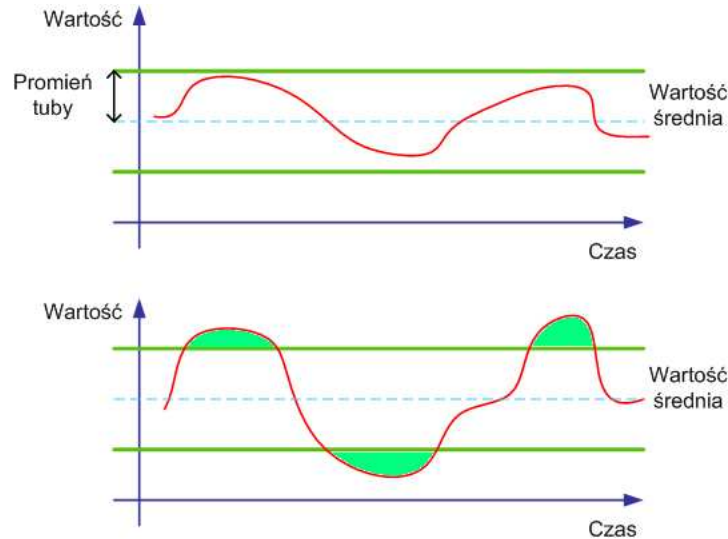
Pierwsze dwa wymagania są ze sobą wzajemnie sprzeczne. Zwiększenie szybkości nauki procesu, zapewniające szybką adaptację do nowych warunków pracy, związane jest ze zwiększeniem częstotliwości powstawania limfocytów typu B. Tak więc aby spełnić wymaganie 1, należy tak skonfigurować moduł uczenia, aby możliwie duża

liczba analizowanych okien czasowych była przekształcana w limfocyt typu B. Chcąc więc zwiększyć częstotliwość powstawania limfocytów należy osłabić warunki jakie musi spełnić okno czasowe, aby można je było przekształcić do postaci limfocytu. Jednym z głównych warunków jest niezmiennosc sygnałów zakłócenia w oknie czasowym. Osłabienie tego warunku jak również i innych warunków okna czasowego jest sprzeczne z wymaganiami 2. Zwiększenie dopuszczalnego zakresu zmian sygnałów zakłócenia powoduje, że zapisane w limfocycie statyczne odpowiedzi procesu na zmianę sterowania są w większym stopniu zakłócone przez zmiany wartości elementów wektora  $z$ . Konfiguracja modułu uczenia jest najważniejszym i najbardziej czasochłonnym zadaniem stojącym przed inżynierem wdrażającym system SILO. Musi on tak dobrać parametry modułu uczenia aby znaleźć optymalny kompromis między sprzecznymi wymaganiami 1 i 2.

Moduł uczenia analizuje w czasie rzeczywistym pomiary wartości punktów procesowych będących elementami wektorów  $x$ ,  $y$  i  $z$ . Pomiary te zbierane są z pewnym okresem próbkowania. Moduł uczenia wyszukuje w danych pomiarowych zmian wartości elementów wektora sterowań. Wykrycie takiej zmiany wiąże się z koniecznością ustalenia, że przez pewien okres czasu wartości elementów wektora  $x$  znajdowały się na pewnym stałym poziomie (z pewną założoną dokładnością), oraz że istnieje inny skojarzony przedział czasowy, w którym wartości elementów wektora  $x$  znajdują się na w przybliżeniu stałym poziomie i różnica wektorów  $x$  zarejestrowanych w obydwu tych przedziałach jest niezerowa. Różnica między tymi wektorami to zmiana wektora sterowania  $\Delta x$ .

W rzeczywistości pomiar obarczony jest szumem, a wartości punktów mogą oscylować wokół pewnej wartości średniej. Wprowadza się więc tak zwane *tuby nieczułości*. Promień tuby nieczułości definiujemy jako maksymalną dopuszczalną odchyłkę chwilowej wartości sygnału od wartości średniej sygnału, liczonej za pewien ustalony okres czasu. Jeżeli w pewnym ustalonym okresie czasu maksymalna różnica między wartością średnią sygnału i chwilową wartością sygnału jest mniejsza od promienia tuby nieczułości, to przyjmuje się, że rozpatrywany sygnał nie zmieniał się w ustalonym okresie czasu (patrz rys. 7.1).

Po wykryciu zmiany sterowania moduł uczenia sprawdza, czy zakłócenia oddziałujące na proces nie zmieniły się w trakcie lub po zmianie sterowania. Tak więc należy sprawdzić, czy zastosowane przeciwciało stara się związać patogen, który był

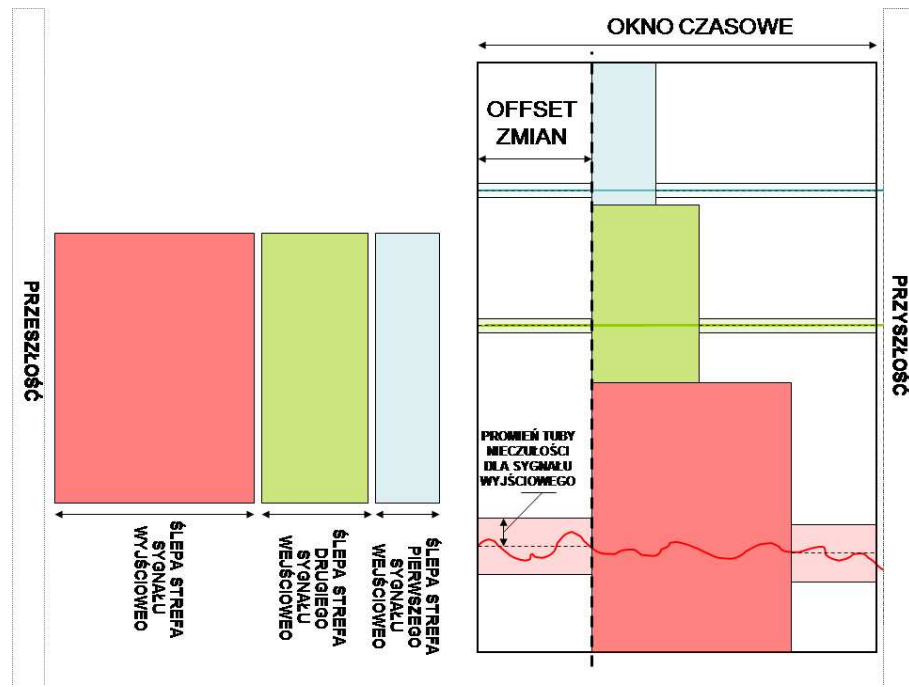


Rysunek 7.1 Moduł uczenia przyjmuje, że: a) sygnał nie zmieniał się, b) sygnał istotnie zmieniał się w rozpatrywanym okresie czasu.

pierwotnym celem przeciwciała. Rejestrując odpowiedź obiektu, rejestrujemy efektywność przeciwciała w walce z konkretnym patogenem. Musimy więc upewnić się, że patogen nie zmienił się w trakcie oceniania efektywności przeciwciała. Innymi słowy moduł uczenia stara się sprostać wymaganiu, aby statyczna odpowiedź obiektu w jak największym stopniu zależała od zmierzonej zmiany wektora sterowań.

Po wykryciu zmiany sterowania, oraz ustaleniu, że elementy wektora  $z$  były w przybliżeniu stałe, moduł uczenia stara się zarejestrować przyrosty wartości elementów wektora  $y$ . W tym celu następuje sprawdzenie, czy sygnały reprezentujące optymalizowane wyjścia były w przybliżeniu stałe (zastosowanie tuby nieczułości) przed zmianą sterowania i po zmianie sterowania. Różnica między tymi poziomami to przyrost wartości elementów wektora wyjściowego  $\Delta y$ . Jeżeli bezwzględna chwilowa odchyłka elementu wektora  $y$  od wartości średniej przed lub po zmianie sterowania będzie większa niż promień tuby nieczułości, wówczas analizowana sytuacja nie zostanie przekształcona do postaci limfocytu typu B.

Należy zwrócić uwagę, że w przypadku punktów procesowych, będących elementami wektora  $x$  lub  $y$ , przyrost wartości nie musi być skokowy. Ze względu na opóźnienia transportowe i inercje, wartości punktów procesowych potrzebują czasu aby ustalić się na nowych poziomach. Dla każdego punktu wprowadza się więc tzw. *ślepą strefę* (patrz rys. 7.2). Jest to przedział czasu (liczony od wystąpienia zmiany sterowania),

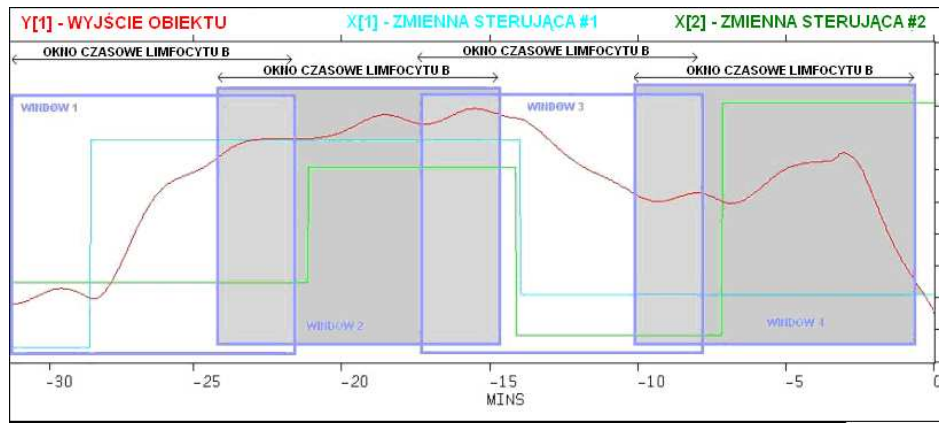


Rysunek 7.2 Oznaczenia okna czasowego.

w którym moduł uczenia nie analizuje czy wartość punktu znajduje się w granicach tuby nieczułości. Długość tej strefy nie powinna być mniejsza niż czas potrzebny na ustalenie się wartości punktu na nowym poziomie.

Zadaniem inżyniera wdrażającego system SILO jest:

- Ustalenie dla każdego elementu wektora  $x$  minimalnej wartości zmiany sterowania, która będzie powodowała przekształcenie analizowanej sytuacji do postaci limfocytu typu B. Im mniejszy będzie ten parametr, tym większy jest wpływ zakłóceń i szumów pomiarowych na zarejestrowaną odpowiedź obiektu;
- Ustalenie dla każdego elementu wektora  $x$  i  $y$  długości *ślepej strefy*. Parametr ten związany jest z szybkością zmian sygnałów sterujących, oraz z dynamiką rozpatrywanego procesu;
- Ustalenie promienia tuby nieczułości dla każdego elementu wektora  $x$ ,  $y$  i  $z$ . Wielkość tego parametru zależy od szumu i oscylacji rozpatrywanego sygnału, oraz od wpływu tego sygnału na statyczną odpowiedź obiektu;



Rysunek 7.3 Cztery kolejne okna czasowe.

- Ustalenie okresu czasowego dla każdego elementu wektora  $x$ ,  $y$  i  $z$ , w którym następuje sprawdzenie czy chwilowe wartości sygnału zawierają się w granicach tuby nieczułości;
- Ustalenie przedziału dopuszczalnych wartości dla każdego elementu wektora  $x$ ,  $y$ ,  $z$ ;
- Ustalenie okresu próbkowania modułu uczenia;
- Ustalenie maksymalnej ilości limfocytów przechowywanych w pamięci immunologicznej (kolejka FIFO).

Aby ułatwić konfigurację modułu uczenia wprowadzono pojęcie okna czasowego (patrz rozdział 6). Na rys. 7.3 pokazano przykład okien czasowych ograniczonych do dwóch elementów wektora  $x$  i jednego elementu wektora  $y$ .

Poniżej przedstawiono warunki konieczne do tego aby móc przekształcić okno czasowe do postaci limfocyty. Spełnienie wszystkich tych warunków powoduje stworzenie nowego limfocyty typu B:

- sygnały zakłóceń oddziałujące na proces w oknie czasowym są stałe w kontekście tuby nieczułości;
- wartości sygnałów sterujących przed zmianą sterowania (przedział czasowy oznaczony przez *offset zmian*, wspólny dla wszystkich elementów wektora  $x$  i  $y$ ) są stałe w kontekście tuby nieczułości;

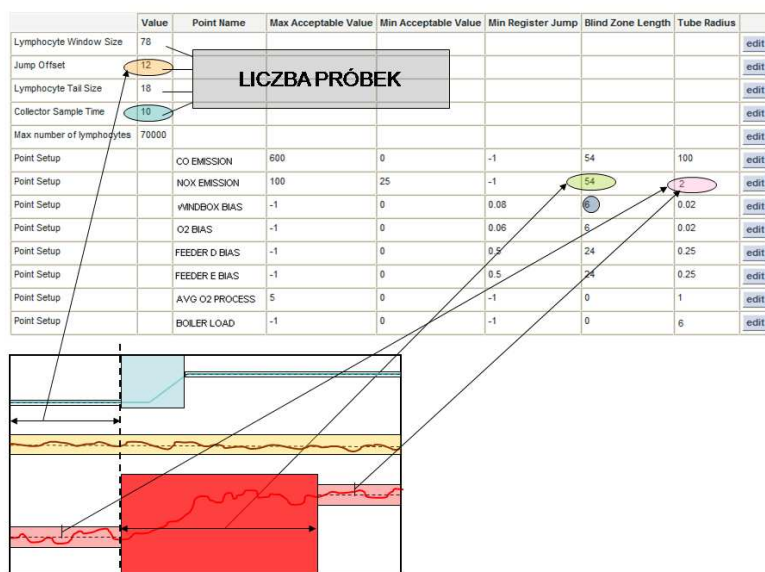


- wartości sygnałów sterujących po zmianie sterowania (przedział czasowy definiowany dla  $k$ -tego sygnału jako *Przedział końcowy*  $[k] = \text{Długość okna czasowego} - \text{offset zmiany} - \text{ślepa strefa } [k]$ ) są stałe w kontekście tuby nieczułości;
- optymalizowane sygnały wyjściowe przed zmianą sterowania (przedział czasowy oznaczony przez *offset zmian*, wspólny dla wszystkich elementów wektora  $x$  i  $y$ ) są stałe w kontekście tuby nieczułości;
- optymalizowane sygnały wyjściowe po zmianie sterowania (przedział czasowy definiowany dla  $k$ -tego sygnału jako *Przedział końcowy*  $[k] = \text{Długość okna czasowego} - \text{offset zmiany} - \text{ślepa strefa } [k]$ ) są stałe w kontekście tuby nieczułości;
- chwilowe wartości punktów procesowych mieszczą się w dopuszczalnych przedziałach wartości, zdefiniowanych dla każdego sygnału.

Tak więc po wprowadzeniu pojęcia okna czasowego zadanie konfiguracji modułu uczenia sprowadza się do określenia:

- okresu próbkowania modułu uczenia;
- maksymalnej liczby limfocytów znajdującej się w pamięci immunologicznej (kolejka FIFO);
- długości okna czasowego;
- długości parametru *offset zmian*;
- długości parametru *ślepa strefa* dla każdego elementu wektora  $x$  i  $y$ ;
- promienia tuby nieczułości dla każdego elementu wektora  $x$ ,  $y$  lub  $z$ ;
- wielkości minimalnej bezwzględnej zmiany sterowania (dla każdego elementu wektora  $x$ ), która będzie uwzględniana przy tworzeniu limfocyту;
- przedziału dopuszczalnych wartości dla każdego punktu procesowego.

Korzystając z dostępnych parametrów inżynier może osłabić lub wzmocnić warunki jakie musi spełnić okno czasowe, aby na jego podstawie można było stworzyć limfocyt typu B. Wpływa to na częstotliwość powstawania limfocytów B (szybkość adaptacji) oraz na jakość przechowywanej w limfocycie wiedzy.



Rysunek 7.4 Przykład okna konfiguracji modułu uczenia.

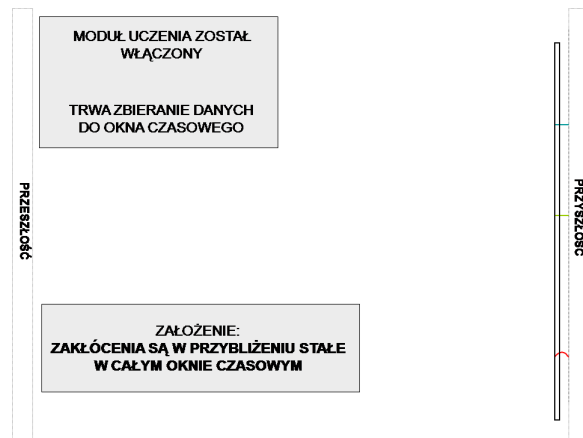
W dalszej części rozdziału zostanie przedstawiony przykład pokazujący działanie modułu uczenia SILO. Aby zrozumieć istotę działania tego modułu należy patrzeć na okno czasowe jak na szablon, który przykłada się do analizowanych sygnałów reprezentujących elementy wektorów  $x$ ,  $y$  i  $z$ .

Na rysunkach 7.5-7.8 przedstawiono proces powstawania okna czasowego po uruchomieniu modułu uczenia SILO. Na rysunku 7.8 wielkość okna jest wystarczająca, aby moduł uczenia rozpoczął analizę tego okna.

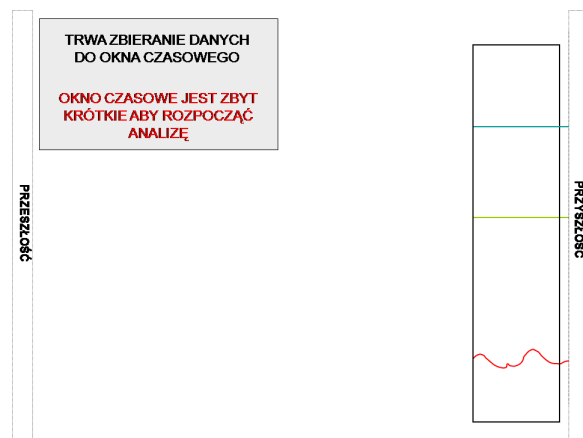
Na rysunku 7.10 pokazano sytuację, w której moduł uczenia wykrył zmianę sygnału sterowania (sygnał o kolorze błękitnym). Okno to nie zostanie jednak przekształcone do postaci limfocytu, ponieważ sygnał sterowania nie zawiera się w granicach tuby nieczułości.

Na rysunku 7.12 pokazano okno czasowe zawierające limfocyt typu B. Po wykryciu limfocytu jest on zapisywany do pamięci immunologicznej. Po wykryciu limfocytu część okna czasowego jest usuwana. Moduł uczenia nie rozpocznie analizy okna czasowego w poszukiwaniu nowego limfocytu, dopóki okno czasowe nie osiągnie wymaganego rozmiaru.

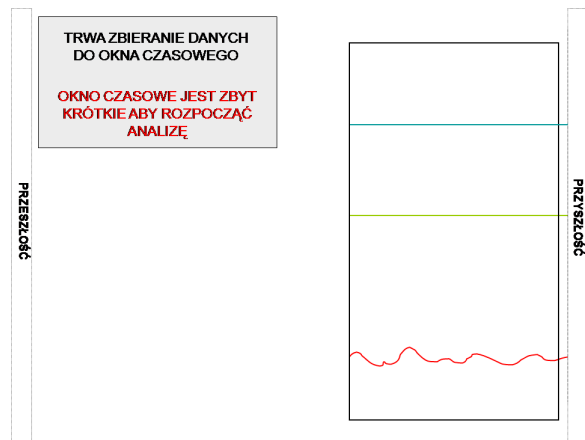
Na rysunkach od 7.14 do 7.17 przedstawiono proces powstawania kolejnego limfocytu B. Tym razem wykryto zmianę dwóch sygnałów sterowania.




Rysunek 7.5 Wykrywanie limfocytu w oknie czasowym - cz. 1.




Rysunek 7.6 Wykrywanie limfocytu w oknie czasowym - cz. 2.



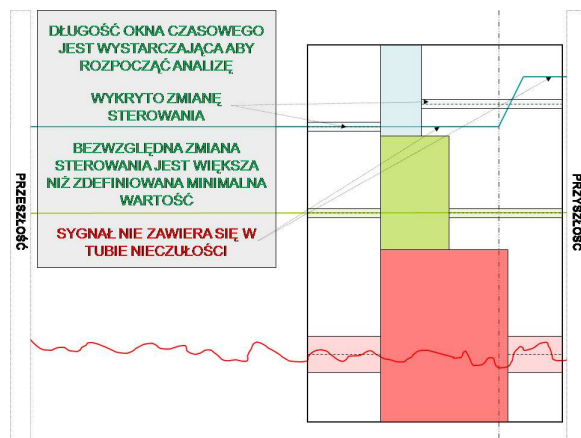
Rysunek 7.7 Wykrywanie limfocytu w oknie czasowym - cz. 3.



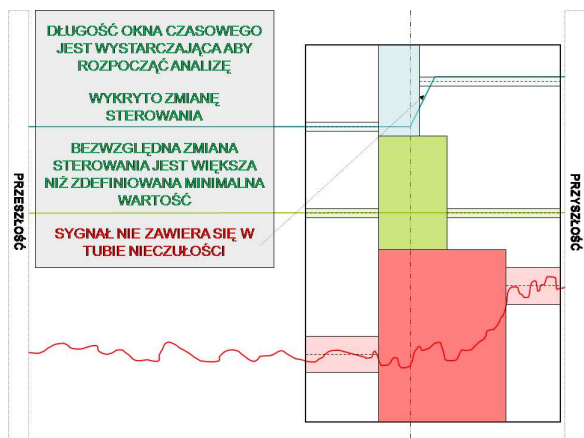
Rysunek 7.8 Wykrywanie limfocytu w oknie czasowym - cz. 4.



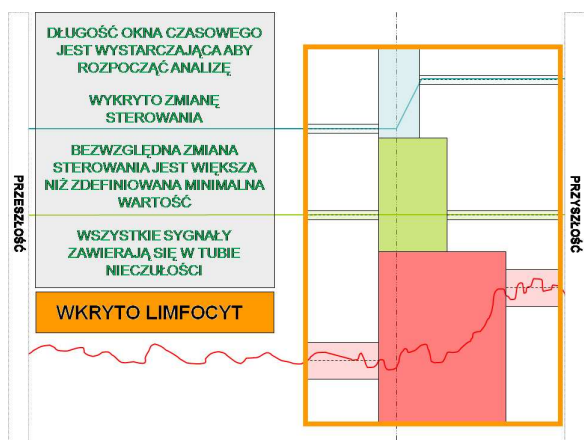
Rysunek 7.9 Wykrywanie limfocytu w oknie czasowym - cz. 5.




Rysunek 7.10 Wykrywanie limfocytu w oknie czasowym - cz. 6.




Rysunek 7.11 Wykrywanie limfocytu w oknie czasowym - cz. 7.



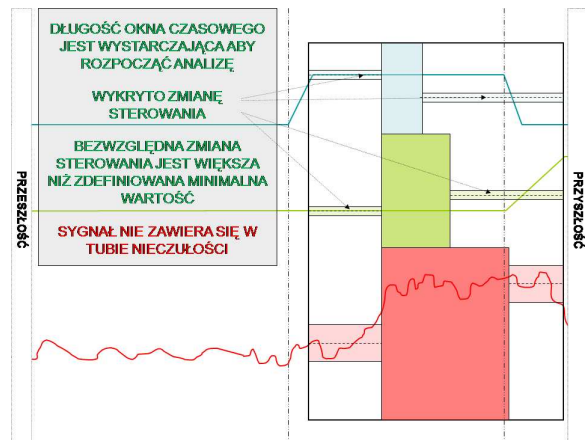
Rysunek 7.12 Wykrywanie limfocytu w oknie czasowym - cz. 8.




Rysunek 7.13 Wykrywanie limfocytu w oknie czasowym - cz. 9.



Rysunek 7.14 Wykrywanie limfocytu w oknie czasowym - cz. 10.

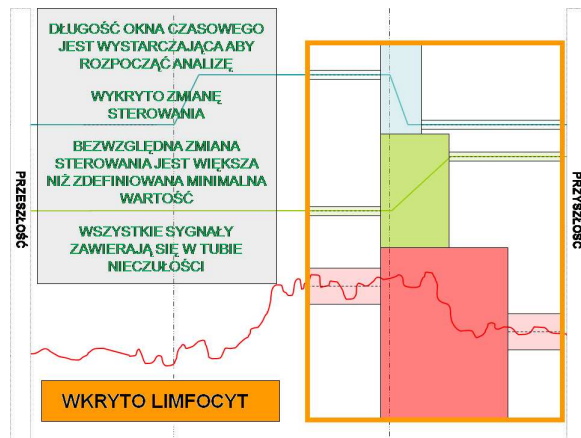


Rysunek 7.15 Wykrywanie limfocytu w oknie czasowym - cz. 11.




Rysunek 7.16 Wykrywanie limfocytu w oknie czasowym - cz. 12.







Rysunek 7.17 Wykrywanie limfocyty w oknie czasowym - cz. 13.



Rysunek 7.18 Wykrywanie limfocyty w oknie czasowym - cz. 14.




Rysunek 7.19 Wykrywanie limfocytu w oknie czasowym - cz. 15.

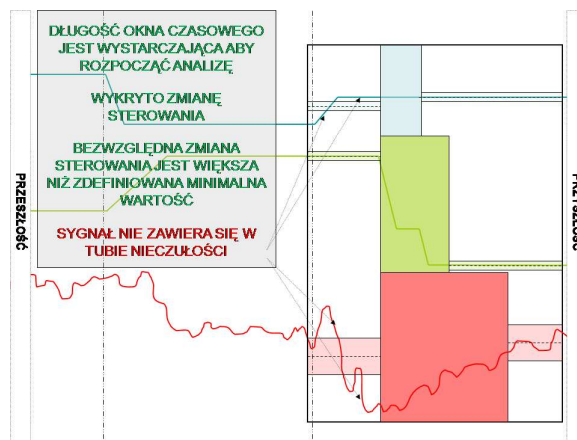


Rysunek 7.20 Wykrywanie limfocytu w oknie czasowym - cz. 16.

Na rysunkach od 7.18 do 7.22 pokazano sytuację, w której pomimo wykrycia zmiany wartości elementów wektora sterowań, okno czasowe nie zostało przekształcone do postaci limfocytu.



Rysunek 7.21 Wykrywanie limfocytu w oknie czasowym - cz. 17.



Rysunek 7.22 Wykrywanie limfocytu w oknie czasowym - cz. 18.

Powyższy przykład ilustruje sposób, w jaki moduł uczenia zdobywa wiedzę o optymalizowanym procesie. Budowa i analiza okna czasowego może odbywać się w czasie rzeczywistym. Możliwa jest także analiza historycznych wartości punktów procesowych zapisanych w pliku. Systemy DCS zwykle wyposażone są w serwery przechowujące historyczne wartości punktów procesowych. W przypadku niektórych obiektów przemysłowych wykorzystanie historycznych wartości punktów procesowych może znacznie przyspieszyć proces zdobywania wiedzy.

Moduł uczenia działa niezależnie od innych modułów (patrz rozdział 6). Moduł optymalizacji generuje zmiany sterowania, które stanowią podstawowy warunek przekształcenia okna czasowego do postaci limfocytu B. Można jednak uruchomić moduł uczenia przy wyłączonym module optymalizacji. Wówczas SILO będzie gromadzić wiedzę o procesie na podstawie zmian wartości sygnałów sterujących wygenerowanych przez operatorów lub inny algorytm regulacji.


## Rozdział 8 Moduł optymalizacji

Moduł optymalizacji to niezależny moduł systemu SILO, którego zadaniem jest obliczanie przyrostów wartości elementów wektora sterowań minimalizujących wskaźnik jakości (8.1). Wartość wskaźnika jakości zależy od wartości elementów wektorów  $x$  i  $y$ .

Zmiana wartości elementów wektora sterowań następuje co ustalony okres optymalizacji. Czas między kolejnymi zmianami sterowań nie może być mniejszy niż łączny czas potrzebny na ustalanie się odpowiedzi obiektu i czas związany z obserwacją procesu po ustaleniu się odpowiedzi. Czas związany z obserwacją procesu po ustaleniu się odpowiedzi wynika z konieczności zbadania, czy przed kolejną zmianą sterowania stan procesu jest ustalony. Sprawdzenie to wykonywane jest przez moduł analizatora stanu, z wykorzystaniem mechanizmu tuby nieczułości (patrz rozdział 7). Na rys. 8.1 pokazano przykład, w którym czterokrotnie zmieniono wektor sterowań. Odpowiedź obiektu ustalała się na pewnym poziomie w przypadku trzech pierwszych zmian sterowania. W przypadku ostatniej zmiany odpowiedź obiektu nie ustaliła się w wymaganym okresie czasu. Mogło to wynikać ze zmiany zakłóceń, interwencji operatora, awarii lub innego działania wpływającego na wyjścia procesu. W takim przypadku moduł analizatora stanu zadecyduje, że stan procesu nie jest ustalony.

Okres optymalizacji w systemie SILO jest zazwyczaj znacznie dłuższy niż w okres zmian sterowania regulatorów MPC. Należy jednak pamiętać, że SILO to system wykorzystujący statyczny model obiektu. Może być stosowany wszędzie tam, gdzie zakłócenia oddziałujące na proces zmieniają się na tyle rzadko, że przez większość czasu stan procesu jest ustalony. Przy takich założeniach czas między kolejnymi zmianami sterowania może być dłuższy niż w przypadku regulatorów MPC.

Dzięki użyciu modelu dynamicznego optymalizowanego procesu regulator MPC potrafi przewidzieć przyszłe dynamiczne zachowanie procesu. Pozwala to na częstsze zmiany wektora sterowań. SILO posiada jedynie wiedzę o statycznych zależnościach



Rysunek 8.1 Cztery kolejne okresy optymalizacji.

występujących w optymalizowanym procesie. Należy jednak pamiętać, że SILO działa w oparciu o podstawowe systemy sterowania (patrz rozdział 4), które potrafią o wiele szybciej (choć mniej dokładnie) zareagować na zmiany zakłócenia. Ponadto struktura połączenia systemu SILO i systemu DCS jest tak zaprojektowana, że SILO może wprowadzać jedynie poprawki do sygnałów wartości zadanych dla podstawowej warstwy regulacji. Dzięki takiemu rozwiązaniu układ sterowania jest w stanie nadążyć za zmianami zakłócenia. Tak więc relatywnie długi okres optymalizacji nie jest problemem w przypadku pewnej klasy procesów, do której należy również proces spalania zachodzący w kotle energetycznym w elektrowniach podszczytowych i zawodowych. Zostało to potwierdzone empirycznie podczas dotychczasowych wdrożeń systemu SILO (patrz rozdział 11).

W systemie SILO nie zastosowano modelu dynamicznego, ze względu na specyfikę działania modułu uczenia (patrz rozdział 7). Należy pamiętać, że system SILO to system samouczący. Automatyczne zdobywanie wiedzy o optymalizowanym procesie to jedna z głównych zalet tego rozwiązania. Dzięki niej system SILO jest w stanie relatywnie szybko zaadaptować się do nowych warunków pracy. Nie trzeba także samodzielnie wykonywać testów parametrycznych i budować modeli matematycznych, co drastycznie zmniejsza czas potrzebny na wdrożenie. Jest to jedna z głównych zalet tego rozwiązania w porównaniu do regulatorów MPC. Zastosowanie modelu dynamicznego pogorszyłoby znacznie efektywność uczenia. W takim przypadku, aby w trybie on-line zdobywać wiedzę o procesie należałoby dysponować bardzo dokładnym wyjściowym modelem dynamiki procesu. Wiązałoby się to z koniecznością przeprowadzenia testów parametrycznych i zbudowaniem modeli matematycznych, zatem czas

potrzebny na wdrożenie regulatora SILO zwiększyłby się do czasu potrzebnego na wdrożenie regulatora MPC. Jest to sprzeczne z założeniami systemu SILO, który to system ma stanowić tanią w sensie ekonomicznym alternatywę dla regulatorów MPC, przeznaczoną dla procesów, w których zakłócenia zmieniają się na tyle rzadko, że stan procesu ustala się na pewnym poziomie, przez dłuższy okres czasu.

Zadaniem modułu optymalizacji jest minimalizacja wskaźnika jakości (8.1). Wskaźnik jakości definiowany jest w oparciu o wybrane przez użytkownika elementy wektorów  $x$  i  $y$ .

$$J = \sum_{k=1}^{nx} \left[ \alpha_k (|x_k^a - x_k^s| - \tau_k^{lx})_+ + \beta_k ( (|x_k^a - x_k^s| - \tau_k^{sx})_+ )^2 \right] + \sum_{k=1}^{ny} \left[ \gamma_k (|y_k^a - y_k^s| - \tau_k^{ly})_+ + \delta_k ( (|y_k^a - y_k^s| - \tau_k^{sy})_+ )^2 \right] \quad (8.1)$$

gdzie:

$\alpha_k$  – waga kary liniowej dla  $k$ -tej zmiennej sterującej;

$\beta_k$  – waga kary kwadratowej dla  $k$ -tej zmiennej sterującej;

$\gamma_k$  – waga kary liniowej dla  $k$ -tego wyjścia procesu;

$\delta_k$  – waga kary kwadratowej dla  $k$ -tego wyjścia procesu;

$\tau_k^{lx}$  – szerokość strefy nieczułości kary liniowej dla  $k$ -tej zmiennej sterującej;

$\tau_k^{sx}$  – szerokość strefy nieczułości kary kwadratowej dla  $k$ -tej zmiennej sterującej;

$\tau_k^{ly}$  – szerokość strefy nieczułości kary liniowej dla  $k$ -tego wyjścia procesu;

$\tau_k^{sy}$  – szerokość strefy nieczułości kary kwadratowej dla  $k$ -tego wyjścia procesu;

$(\cdot)_+$  – operator opisany równaniem  $(x)_+ = \frac{1}{2}(x + |x|)$ ;

$x_k^s$  – wartość zadana dla  $k$ -tej zmiennej sterującej;


$y_k^s$  – wartość zadana dla  $k$ -tego wyjścia procesu;

$x_k^a$  – aktualna wartość  $k$ -tej zmiennej sterującej;

$y_k^a$  – aktualna wartość  $k$ -tego wyjścia procesu.

Analizując wzór (8.1) widać, że karane są odchyłki wartości wybranych elementów wektorów  $x$  i  $y$ , od wartości zadanych. Wprowadzenie operatora  $(\cdot)_+$  powoduje, że kara nakładana jest na wybrany element wektora  $x$  lub  $y$ , tylko jeżeli bezwzględna odchyłka od zadanej wartości jest większa niż pewna wartość graniczna. Wprowadzenie członu liniowego i kwadratowego umożliwi dokładniejsze sprecyzowanie celów optymalizacji.

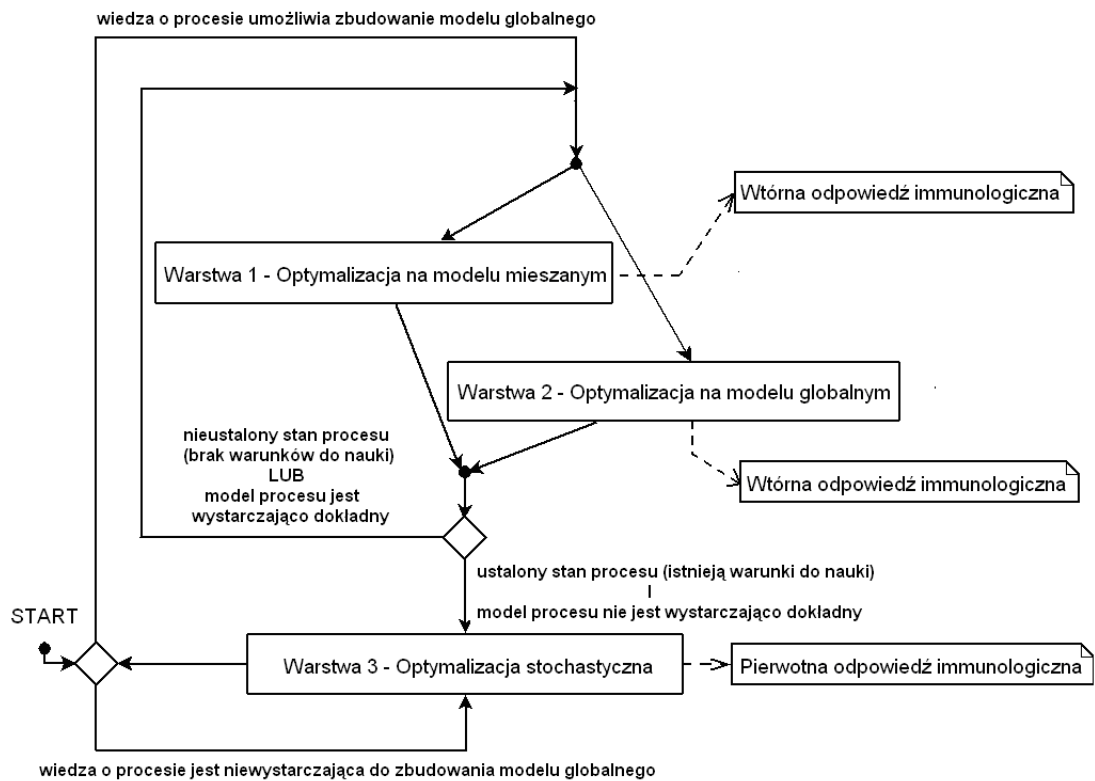
**Przykład 8.0.1** *Przyjęto, że jednym z regulowanych wyjść procesu spalania w kotle energetycznym jest temperatura pary świeżej na wyjściu z kotła. Zadaniem systemu SILO jest utrzymanie tej temperatury na poziomie  $540^\circ\text{C}$ . Akceptowane są odchyłki o  $3^\circ\text{C}$  od przyjętej wartości zadanej. Na rysunku 8.2 przedstawiono przykład funkcji kary dla temperatury pary świeżej. Kara liniowa aktywowana jest, gdy wartość temperatury pary będzie większa od  $543^\circ\text{C}$  lub mniejsza od  $537^\circ\text{C}$ . W przypadku gdy wartość temperatury pary przekroczy  $550^\circ\text{C}$  lub spadnie poniżej  $530^\circ\text{C}$ , wówczas do kary liniowej dodawana jest kara kwadratowa. Rozpatrywany w niniejszym przykładzie sygnał temperatury pary świeżej to w istocie sygnał niosący informację o estymowanej temperaturze pary świeżej, która wystąpiłaby gdyby wtryski schładzające były wyłączone (patrz rozdział 11.2).*



Rysunek 8.2 Przykład funkcji kary dla temperatury pary świeżej.

Algorytm optymalizacji pracuje w jednej z trzech warstw optymalizacji (rys. 8.3). W każdej warstwie przyjęto inny algorytm obliczania optymalnego przyrostu sterowań minimalizującego wskaźnik jakości (8.1). Kluczowym elementem systemu SILO jest algorytm przełączania między warstwami. Użycie poszczególnych warstw zależy od





Rysunek 8.3 Uproszczony schemat warstwowego algorytmu optymalizacji.

stanu wiedzy systemu SILO, oraz od aktualnego stanu procesu. W sposób najbardziej ogólny można powiedzieć, że:

- Warstwa optymalizacji stochastycznej odpowiada stochastycznej eksploracji przestrzeni rozwiązań. Wykonywana jest gdy SILO nie posiada żadnej wiedzy o procesie, lub gdy wiedza ta przestaje być wystarczająca. Rozwiązanie znalezione w tej warstwie jest punktem startowym optymalizacji w warstwach korzystających z modelu procesu. Stosując analogię do układu odpornościowego warstwa ta realizuje pierwotną odpowiedź immunologiczną (patrz rozdział 3);
- Warstwa optymalizacji na modelu globalnym używa ogólnej wiedzy o optymalizowanym procesie w celu obliczenia optymalnego przyrostu sterowań. Automatycznie konstruowany model matematyczny wykorzystywany w tej warstwie agreguje wiedzę o podstawowych zależnościach optymalizowanego procesu. Warstwa ta wykonywana jest gdy SILO nie dysponuje wystarczającą wiedzą o procesie w aktualnym punkcie pracy i w związku z tym niemożliwe jest zbudowanie modelu matematycznego reprezentującego statyczne zależności istniejące w obiekcie w okolicy aktualnego punktu pracy. Do budowy modelu wykorzystywana jest wiedza zebrana we wszystkich zmierzonych punktach pracy;
- Warstwa optymalizacji na modelu mieszanym wykorzystuje informacje zebrane przez moduł uczenia do zbudowania modelu matematycznego reprezentującego statyczne zależności istniejące w optymalizowanym procesie w okolicy aktualnego punktu pracy. Do budowy modelu matematycznego wykorzystywana jest wiedza o zachowaniu procesu w okolicy aktualnego punktu pracy, przez co model matematyczny jest bardziej dokładny niż modele zbudowane w warstwie optymalizacji na modelu globalnym. Opisywana warstwa odpowiada eksploatacji przestrzeni rozwiązań. Stosując analogię do układu odpornościowego warstwa ta realizuje wtórną odpowiedź immunologiczną (patrz rozdział 3).

W kolejnych podpunktach zostaną szczegółowo omówione poszczególne warstwy.

## 8.1 Warstwa optymalizacji na modelu mieszanym

Warstwa ta jest wykonywana w przypadku gdy system SILO dysponuje odpowiednią wiedzą na temat zachowania obiektu regulacji w otoczeniu aktualnego punktu pracy. Oznacza to, że w pamięci immunologicznej znajduje się wystarczająca ilość

limfocytów reprezentujących podobny stan procesu do aktualnego. W warstwie tej w każdym kroku optymalizacji automatycznie tworzony jest liniowy, przyrostowy model matematyczny procesu w otoczeniu aktualnego punktu pracy. Do stworzenia tego modelu system SILO wykorzystuje informacje zgromadzone w  $l$  najmłodszych limfocytach *lokalnych* i  $g$  najmłodszych limfocytach *globalnych*. Zbiór limfocytów globalnych to zbiór wszystkich limfocytów znajdujących się w pamięci immunologicznej. Zbiór limfocytów lokalnych to zbiór limfocytów, które spełniają warunki podobieństwa. Dla limfocytów lokalnych prawdziwa jest równość  $\mu(L_k, A) = 1$  (patrz rozdział 5.3).

W algorytmie opisanym w [115, 116] system SILO wykorzystywał wszystkie limfocyty lokalne i wszystkie limfocyty globalne do budowy modelu matematycznego. W artykule [119] zaprezentowano nową wersję algorytmu, w której wprowadzono znaczniki czasowe dla każdego limfocyty typu B. Dzięki tej zmianie system SILO używa do budowy modelu matematycznego jedynie najmłodszych limfocytów. Powoduje to szybszą adaptację do zmieniających się warunków pracy związanych m.in. ze zużyciem urządzeń wykonawczych, sezonowymi zmianami warunków zewnętrznych itp.

Liniowy, przyrostowy model procesu reprezentuje statyczny wpływ zmiany wektora sterowań ( $\Delta x$ ) na zmianę wektora optymalizowanych wyjść procesu ( $\Delta y$ )

$$\Delta y = \Delta x K, \quad (8.2)$$

gdzie  $\Delta x = [\Delta x_1, \Delta x_2, \dots, \Delta x_{nx}]$ ,  $\Delta y = [\Delta y_1, \Delta y_2, \dots, \Delta y_{ny}]$ , a macierz  $K$  reprezentuje macierz wzmocnień.

Elementy macierzy  $K$  estymowane są na podstawie informacji zapisanych w lokalnych macierzach obserwacji  $\Delta X_L$  i  $\Delta Y_L$ , oraz w globalnych macierzach obserwacji  $\Delta X_G$  i  $\Delta Y_G$ . Macierze te mają następującą postać

$$\Delta X_L = \begin{bmatrix} \Delta x_{1,1} & \Delta x_{1,2} & \dots & \Delta x_{1,nx} \\ \Delta x_{2,1} & \Delta x_{2,2} & \dots & \Delta x_{2,nx} \\ \vdots & \vdots & \ddots & \vdots \\ \Delta x_{l,1} & \Delta x_{l,2} & \dots & \Delta x_{l,nx} \end{bmatrix}, \Delta Y_L = \begin{bmatrix} \Delta y_{1,1} & \Delta y_{1,2} & \dots & \Delta y_{1,ny} \\ \Delta y_{2,1} & \Delta y_{2,2} & \dots & \Delta y_{2,ny} \\ \vdots & \vdots & \ddots & \vdots \\ \Delta y_{l,1} & \Delta y_{l,2} & \dots & \Delta y_{l,ny} \end{bmatrix}.$$

Każdy z  $l$  wierszy macierzy  $\Delta X_L$  zawiera przyrost wartości elementów wektora sterowań ( $\Delta x$ ) zapisany w lokalnym limfocycie typu B (należącym do zbioru  $l$  najmłodszych limfocytów lokalnych). Analogicznie macierz  $\Delta X_G$  zawiera przyrosty zmienionych sterujących przechowywane w  $g$  najmłodszych limfocytach globalnych. Każdy z  $l$  wierszy macierzy  $\Delta Y_L$  zawiera przyrost wartości elementów wektora wyjść procesu ( $\Delta y$ ) zapisany w lokalnym limfocycie typu B (należącym do zbioru  $l$  najmłodszych

limfocytów lokalnych). Analogicznie macierz  $\Delta Y_G$  zawiera przyrosty wyjść procesu przechowywane w  $g$  najmłodszych limfocytach globalnych.

W celu estymacji elementów macierzy  $K$  wykorzystuje się Metodę Najmniejszych Kwadratów. Rozważmy przypadek estymacji elementów macierzy  $K$  znajdujących się w kolumnie macierzy  $K$ , związanej tylko z jednym optymalizowanym wyjściem. Przy założeniu liniowości statycznej charakterystyki procesu w okolicy aktualnego punktu pracy, zależność między wejściami i wyjściami procesu można wyrazić w następujący sposób

$$\Delta y = \Delta X \zeta + \varepsilon$$

gdzie:

$$\Delta y = \begin{bmatrix} \Delta y_1 \\ \Delta y_2 \\ \dots \\ \Delta y_m \end{bmatrix}, \zeta = \begin{bmatrix} \zeta_1 \\ \zeta_2 \\ \dots \\ \zeta_{nx} \end{bmatrix}, \varepsilon = \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \dots \\ \varepsilon_m \end{bmatrix}, \varepsilon_i \sim N(0, \sigma^2),$$

$$\Delta X = \begin{bmatrix} \Delta x_{1,1} & \Delta x_{1,2} & \dots & \Delta x_{1,nx} \\ \dots & \dots & \dots & \dots \\ \Delta x_{m,1} & \Delta x_{m,2} & \dots & \Delta x_{m,nx} \end{bmatrix}$$

Celem Metody Najmniejszych Kwadratów jest znalezienie takiego estymatora  $k$  parametru  $\zeta$ , który minimalizuje sumę kwadratów reszt. Reszty z modelu definiujemy jako

$$e = \Delta y - \Delta X k$$

Wprowadzono dodatkowe wagi  $\eta$  i  $\vartheta$ . Określają one w jakim stopniu poszukiwany model ma zależeć od informacji zapisanych w limfocytach lokalnych, a w jakim od informacji zapisanych w limfocytach globalnych. Znaczenie tych wag zostanie dokładniej opisane w dalszej części rozdziału. Sumie kwadratów reszt związanych z limfocytami lokalnymi przypisano wagę  $\eta$ , a sumie kwadratów reszt związanych z limfocytami globalnymi przypisano wagę  $\vartheta$ . Ważona suma kwadratów reszt opisana jest następującym wzorem

$$\begin{aligned} S(k) &= \eta e_L^T e_L + \vartheta e_G^T e_G = \\ &= \eta (\Delta y_L - \Delta X_L k)^T (\Delta y_L - \Delta X_L k) + \vartheta (\Delta y_G - \Delta X_G k)^T (\Delta y_G - \Delta X_G k) = \\ &= \eta (\Delta y_L^T \Delta y_L - 2k^T \Delta X_L^T \Delta y_L + k^T \Delta X_L^T \Delta X_L k) + \\ &\quad + \vartheta (\Delta y_G^T \Delta y_G - 2k^T \Delta X_G^T \Delta y_G + k^T \Delta X_G^T \Delta X_G k) \end{aligned}$$

Minimalizacja funkcji  $S(k)$  względem wektora  $k$  odbywa się poprzez wyznaczenie pochodnej funkcji  $S(k)$

$$\frac{\partial S(k)}{\partial k} = -\eta 2\Delta X_L^T \Delta y_L + \eta 2\Delta X_L^T \Delta X_L k - \vartheta 2\Delta X_G^T \Delta y_G + \vartheta 2\Delta X_G^T \Delta X_G k$$

a następnie przyrównanie tej pochodnej do zera. Uzyskuje się w ten sposób układ równań normalnych

$$(\eta \Delta X_L^T \Delta X_L + \vartheta \Delta X_G^T \Delta X_G) k = \eta \Delta X_L^T \Delta y_L + \vartheta \Delta X_G^T \Delta y_G$$

Rozwiązując ten układ dla  $k$  otrzymuje się analityczną postać rozwiązania

$$k = (\eta \Delta X_L^T \Delta X_L + \vartheta \Delta X_G^T \Delta X_G)^{-1} (\eta \Delta X_L^T \Delta y_L + \vartheta \Delta X_G^T \Delta y_G)$$

Uogólniając powyższe rozważania dla przypadku obiektu posiadającego wiele optymalizowanych wyjść uzyskuje się następującą postać równania normalnego

$$WK = V \tag{8.3}$$

gdzie:

$$W = \eta \Delta X_L^T \Delta X_L + \vartheta \Delta X_G^T \Delta X_G$$

$$V = \eta \Delta X_L^T \Delta y_L + \vartheta \Delta X_G^T \Delta y_G$$

Wówczas analityczna postać rozwiązania jest następująca

$$K = W^{-1}V$$

Aby zadanie identyfikacji modelu było zawsze dobrze uwarunkowane zmodyfikowano równanie normalne (8.3) poprzez dodanie tzw. *modelu bezpiecznego*

$$(W + \mu I) K = (V + \mu M) \tag{8.4}$$

$$K = (W + \mu I)^{-1} (V + \mu M) \tag{8.5}$$

gdzie:

$M$  – macierz reprezentująca bezpieczny model,

$\mu$  – waga modelu bezpiecznego.

Wprowadzenie macierzy  $\mu I$  oraz  $\mu M$  zapewnia, że równanie (8.4) będzie dobrze uwarunkowane nawet w przypadku, gdy macierz  $W$  będzie osobliwa. Współczynnik  $\mu$  jest zazwyczaj bardzo mały w porównaniu do  $\eta$  i  $\vartheta$ , przez co rozwiązanie zadania (8.4) nie jest istotnie modyfikowane. Elementy macierzy  $M$  reprezentują wzmocnienia modelu bezpiecznego. Estymacja wartości tych elementów dokonywana jest na podstawie eksperckiej wiedzy na temat optymalizowanego procesu. Wartości wzmocnień modelu bezpiecznego zmieniane są ręcznie przez eksperta. Zwiększanie wagi  $\mu$  powoduje, że rozwiązanie zadania identyfikacji modelu (8.4) jest w większym stopniu przyciągane przez macierz  $M$ . Jeżeli inżynier wdrażający system SILO nie posiada *a priori* wiedzy o wzmocnieniach obiektu, wówczas elementom macierzy  $M$  przypisywane są zerowe wartości, a waga  $\mu$  jest bardzo mała w porównaniu do wagi  $\eta$  i  $\vartheta$ .

Należy zauważyć, że macierz  $W + \mu I$  jest macierzą symetryczną i nieosobliwą. Można zatem w sposób numeryczny wyznaczyć wartości elementów macierzy  $K$  rozwiązując równanie normalne (8.4). W tym celu dokonuje się rozkładu QR [97] macierzy  $W + \mu I$ . Takie postępowanie jest bardziej efektywne niż wyznaczanie macierzy  $K$  w sposób analityczny, korzystając z równania (8.5). W dotychczasowych wdrożeniach systemu SILO (patrz rozdział 11), wszystkie elementy macierzy  $M$  miały zerową wartość, a waga  $\mu$  była bardzo mała w porównaniu do  $\eta$  i  $\vartheta$ .

W warstwie optymalizacji na modelu mieszanym system SILO używa limfocytów globalnych jedynie po to aby zwiększyć odporność SILO na błędne informacje, które mogą znaleźć się w limfocytach lokalnych. Możemy wyobrazić sobie sytuację, w której nastąpiła awaria urządzenia pomiarowego. Załóżmy ponadto, że awaria ta nie zostanie wykryta przez prosty algorytm wykrywający stany awaryjne, zaimplementowany w module uczenia, oraz że operator procesu który wie o awarii zapomniał wyłączyć modułu uczenia SILO. Wówczas SILO nadal będzie uczył się procesu, jednak wiedza ta nie będzie reprezentatywna. Użycie tylko takiej wiedzy do budowy modelu matematycznego nie prowadziłyby do dobrych rezultatów. Aby wyeliminować takie niebezpieczeństwo wprowadza się do modelu także pewną ogólną wiedzę o procesie, zgromadzoną w limfocytach globalnych. Przyjmuje się, że liczba limfocytów globalnych użytych do budowy modelu matematycznego jest dużo większa niż liczba limfocytów lokalnych.

Użycie limfocytów globalnych do budowy modelu matematycznego w okolicy aktualnego punktu pracy poprawia odporność SILO na błędne informacje zapisane w limfocytach w pamięci immunologicznej, może jednak powodować, że tak skonstruowane

modele będą mniej dokładne niż modele zbudowane jedynie na podstawie limfocytów lokalnych. Wprowadzono więc wagi, za pomocą których użytkownik może decydować, czy zależy mu na zwiększeniu odporności kosztem dokładności, czy zadanie identyfikacji modelu ma być bardziej dokładne, ale mniej odporne na błędne pomiary zapisane w limfocytach w pamięci immunologicznej. W przypadku optymalizacji procesu spalania w kotle energetycznym najczęściej przyjmuje się, że waga limfocytów lokalnych jest dziesięciokrotnie większa niż waga limfocytów globalnych. W przypadku silnie nieliniowych procesów waga limfocytów globalnych powinna być bliska zeru.

Wprowadzenie limfocytów globalnych do modelu mieszanego może znacznie poprawić jakość modelu w sytuacji, w której żaden z limfocytów lokalnych nie zawiera informacji o wpływie wybranego elementu wektora  $x$  na wyjścia procesu, podczas gdy informacja taka dostępna jest w zbiorze limfocytów globalnych. W takiej sytuacji, gdyby limfocyty globalne nie były używane do budowy modelu mieszanego, wartości elementów macierzy  $K$  (wzmocnienia modelu), mogłyby znacząco odbiegać od rzeczywistości. Wynikałoby to z tego, że macierz  $\Delta X_L^T \Delta X_L$  była by macierzą osobliwą. Użycie limfocytów globalnych, nawet z bardzo małą wagą, powoduje że w takiej sytuacji macierz  $W$  jest macierzą nieosobliwą, dzięki czemu wzmocnienia modelu obiektu będą lepiej odzwierciedlać rzeczywistość. Jedynie wartość wzmocnienia dla zmiennej sterującej dla której nie zarejestrowano przyrostu w żadnym z limfocytów lokalnych może być niedokładna.

**Przykład 8.1.1** *W jednej z amerykańskich elektrowni system SILO przez zdecydowaną większość czasu pracuje w warunkach dużego obciążenia bloku energetycznego. Po kilku miesiącach od zakończenia wdrożenia zarząd elektrowni zmodyfikował plan produkcji energii w taki sposób, że w trakcie nocy moc bloku spada do niskich wartości. Wówczas podajniki węgla i młyny węglowe, dostarczające mieszanek paliwowo-powietrzną do części palników są wyłączane. Podczas normalnej pracy w warunkach dużego obciążenia wszystkie podajniki paliwa były włączone i system SILO mógł kontrolować prędkość tych podajników. Zatem moduł uczenia mógł zebrać wiedzę o wpływie zmian prędkości podajników węgla na wyjścia procesu w warunkach wysokiego obciążenia bloku energetycznego. W nocy, gdy moc bloku była mała, moduł uczenia nie mógł zdobyć wiedzy o wpływie zmian prędkości wybranych podajników paliwa na wyjścia procesu, gdyż podajniki te były wyłączone. W takiej sytuacji, gdyby waga modelu globalnego i modelu bezpiecznego była równa zero, równanie (8.4) byłoby źle uwarunkowane, a zatem wartości wzmocnień modeli mieszanych, zbudowanych na podstawie*

*limfocytów lokalnych nie zawierających wiedzy o niektórych zmiennych sterujących, znacząco odbiegałyby od rzeczywistości. Wprowadzenie do modelu mieszanego limfocytów globalnych powoduje, że zadanie identyfikacji modelu procesu jest dobrze uwarunkowane. Jedynie wzmocnienia elementów wektora  $x$ , związanych z prędkością podajników węgla, mają niedokładne wartości. Nie stanowi to jednak problemu, gdyż ze względu na wyłączenie rozpatrywanych podajników paliwa, wymiar zadania optymalizacji jest zmniejszony o te elementy wektora  $x$ , które są związane z wyłączonymi podajnikami. System SILO nie wykorzystuje więc informacji o elementach macierzy  $K$ , reprezentujących wyłączone podajniki. Należy jednocześnie podkreślić, że w przypadku wdrożenia systemu SILO w omawianej elektrowni, waga limfocytów globalnych jest niewielka i wynosi zaledwie 10 % (waga limfocytów lokalnych wynosi 90 %).*

Matematyczny model procesu jest automatycznie tworzony w każdym kroku optymalizacji w warstwie optymalizacji na modelu mieszanym. Za każdym razem, gdy SILO oblicza nowe przyrosty sterowań, nowy model jest tworzony w okolicy aktualnego punktu pracy. Dzięki tej właściwości system SILO używa modelu, który wykorzystując wiedzę zgromadzoną w pamięci immunologicznej, możliwie najdokładniej aproksymuje statyczne zależności procesu w okolicy aktualnego punktu pracy. Użyty model opisuje statyczne relacje między przyrostem optymalizowanych wyjść i przyrostem zmiennych sterujących. W [113] przedstawione było podejście, w którym wykorzystywano model reprezentujący statyczny wpływ zmiennych sterujących i mierzonych zakłóceń na wektor wyjść procesu. Model ten opisany jest wzorem

$$y = f(x, z) \tag{8.6}$$

Eksperymenty przeprowadzone w jednej z polskich elektrowni pokazały, że użycie modelu opisanego równaniem (8.6) daje gorsze rezultaty, niż użycie modelu opisanego równaniem przyrostowym (8.2). Wynika to z konieczności wnioskowania o wartości niemierzalnych lub rzadko mierzonych zakłóceń (wektor  $d$ ). Nie mając informacji o niemierzalnych zakłóceniach nie jest możliwe zbudowanie dokładnego modelu obiektu regulacji, opisanego zależnością (8.6). Stan wyjść procesu zależy od wielu nieuwzględnianych parametrów. W przypadku procesu spalania są to m.in.: temperatura zewnętrzna, wilgotność węgla, kaloryczność węgla itp. Eksperyment przeprowadzony w jednej z polskich elektrowni pokazał, że model matematyczny nie uwzględniający wymienionych informacji nie jest wystarczająco dokładny, aby na jego podstawie optymalizować funkcję celu w sposób zadowalający. Użycie modelu przyrostowego



opisanego równaniem (8.2) okazało się rozwiązaniem dającym zdecydowanie lepsze rezultaty.

Wskaźnik jakości (8.1) minimalizowany jest w oparciu o model (8.2). Algorytm optymalizacji uwzględnia narzucone przez użytkownika ograniczenia na maksymalną zmianę sterowania w jednym kroku optymalizacji i na zakres wartości, które może przyjmować wybrany element wektor  $x$ . Zadanie optymalizacji jest sformułowane następująco

$$\begin{aligned} \min_{\Delta x} \left\{ \sum_{k=1}^{nx} \left[ \alpha_k (|x_k^a + \Delta x_k - x_k^s| - \tau_k^{lx})_+ + \right. \right. \\ \left. \left. + \beta_k ((|x_k^a + \Delta x_k - x_k^s| - \tau_k^{sx})_+)^2 \right] + \right. \\ \left. + \sum_{k=1}^{ny} \left[ \gamma_k (|y_k^a + \Delta x K_k - y_k^s| - \tau_k^{ly})_+ + \right. \right. \\ \left. \left. + \delta_k ((|y_k^a + \Delta x K_k - y_k^s| - \tau_k^{sy})_+)^2 \right] \right\} \end{aligned} \quad (8.7)$$

przy ograniczeniach

$$z_{low} \leq \Delta x \leq z_{hi},$$

$$u_{low} \leq x^a + \Delta x \leq u_{hi}$$

gdzie  $K_k$  to  $k$ -ta kolumna macierzy wzmocnień  $K$ . Analizując powyższe zadanie optymalizacji widać pewną analogię do zadania omawianego w [89]. W pracy tej autorzy przedstawili rozwiązanie zadania minimalizacji różnicy między zadanymi wartościami elementów wektorów  $x$  oraz  $y$  i estymowanymi wartościami elementów tych wektorów w stanie ustalonym. Rozwiązanie to uwzględnia ograniczenia związane z wejściami i wyjściami procesu. Podejście omówione w pracy [89] jest jedną z możliwych realizacji algorytmu SSTO (ang. Steady-State Target Optimization) stanowiącego jeden z poziomów warstwowej struktury regulacji [101] (patrz rys. 2.3 w rozdziale 2).

Zadanie (8.7) może być sformułowane w postaci zadania LQ (8.8). W dalszych rozważaniach przyjęto następujące oznaczenia

$$x_k^n = x_k^a + \Delta x_k$$

$$y_k^n = y_k^a + \Delta x K_k$$

$$J_k^{lx} = \alpha_k (|x_k^n - x_k^s| - \tau_k^{lx})_+$$

$$J_k^{sx} = \beta_k ((|x_k^n - x_k^s| - \tau_k^{sx})_+)^2$$

$$J_k^{ly} = \gamma_k \left( |y_k^n - y_k^s| - \tau_k^{ly} \right)_+$$

$$J_k^{sy} = \delta_k \left( (|y_k^n - y_k^s| - \tau_k^{sy})_+ \right)^2$$

Liniową część minimalizowanego wskaźnika jakości z równania (8.7) związaną z  $k$ -tą zmienną sterującą można wyrazić w następujący sposób

$$J_k^{lx} = \begin{cases} \alpha_k (x_k^n - x_k^s - \tau_k^{lx}) & \text{dla } x_k^n - x_k^s - \tau_k^{lx} \geq 0 \\ \alpha_k (x_k^s - x_k^n - \tau_k^{lx}) & \text{dla } x_k^s - x_k^n - \tau_k^{lx} \geq 0 \\ 0 & \text{dla } x_k^s - \tau_k^{lx} < x_k^n < x_k^s + \tau_k^{lx} \end{cases}$$

Po wprowadzeniu dodatkowych zmiennych  $x_k^{dlp}$  i  $x_k^{dln}$  zadanie minimalizacji kary liniowej dla  $k$ -tej zmiennej sterującej może być zapisane w następujący sposób

$$\min_{\Delta x_k, x_k^{dlp}, x_k^{dln}} J_k^{lx} = \alpha_k (x_k^{dlp} + x_k^{dln})$$

przy ograniczeniach

$$\begin{aligned} x_k^{dlp} &\geq 0 \\ x_k^{dlp} &\geq x_k^n - (x_k^s + \tau_k^{lx}) \\ x_k^{dln} &\geq 0 \\ x_k^{dln} &\geq (x_k^s - \tau_k^{lx}) - x_k^n \end{aligned}$$

gdzie:

- $x_k^{dlp}$  to odległość między  $x_k^n$  i prawym krańcem obszaru o promieniu  $\tau_k^{lx}$  i środku w  $x_k^s$ ,
- $x_k^{dln}$  to odległość między  $x_k^n$  i lewym krańcem obszaru o promieniu  $\tau_k^{lx}$  i środku  $x_k^s$ .

Kwadratową część minimalizowanego wskaźnika jakości z równania (8.7) związaną z  $k$ -tą zmienną sterującą można wyrazić w następujący sposób

$$J_k^{sx} = \begin{cases} \beta_k (x_k^n - x_k^s - \tau_k^{sx})^2 & \text{dla } x_k^n - x_k^s - \tau_k^{sx} \geq 0 \\ \beta_k (x_k^s - x_k^n - \tau_k^{sx})^2 & \text{dla } x_k^s - x_k^n - \tau_k^{sx} \geq 0 \\ 0 & \text{dla } x_k^s - \tau_k^{sx} < x_k^n < x_k^s + \tau_k^{sx} \end{cases} \Leftrightarrow$$

$$\Leftrightarrow J_k^{sx} = \begin{cases} \beta_k (x_k^n - x_k^s - \tau_k^{sx})^2 & \text{dla } x_k^n - x_k^s - \tau_k^{sx} \geq 0 \\ \beta_k (x_k^n - x_k^s + \tau_k^{sx})^2 & \text{dla } x_k^s - x_k^n - \tau_k^{sx} \geq 0 \\ 0 & \text{dla } x_k^s - \tau_k^{sx} < x_k^n < x_k^s + \tau_k^{sx} \end{cases}$$

Po wprowadzeniu dodatkowej zmiennej  $x_k^{ds}$  zadanie minimalizacji kary kwadratowej dla  $k$ -tej zmiennej sterującej może być zapisane w następujący sposób

$$\min_{\Delta x_k, x_k^{ds}} J_k^{sx} = \beta_k (x_k^n - x_k^s - x_k^{ds})^2$$

przy ograniczeniach

$$-\tau_k^{sx} \leq x_k^{ds} \leq \tau_k^{sx}$$

Analogiczne postępowanie prowadzi do sformułowania zadania minimalizacji kary liniowej dla  $k$ -tej zmiennej wyjściowej

$$\min_{\Delta x, y_k^{dlp}, y_k^{dln}} J_k^{ly} = \gamma_k (y_k^{dlp} + y_k^{dln})$$

przy ograniczeniach

$$\begin{aligned} y_k^{dlp} &\geq 0 \\ y_k^{dlp} &\geq y_k^n - (y_k^s + \tau_k^{ly}) \\ y_k^{dln} &\geq 0 \\ y_k^{dln} &\geq (y_k^s - \tau_k^{ly}) - y_k^n \end{aligned}$$

gdzie:

- $y_k^{dlp}$  to odległość między  $y_k^n$  i prawym krańcem obszaru o promieniu  $\tau_k^{ly}$  i środku w  $y_k^s$ ,
- $y_k^{dln}$  to odległość między  $y_k^n$  i lewym krańcem obszaru o promieniu  $\tau_k^{ly}$  i środku  $y_k^s$ .

Zadanie minimalizacji kary kwadratowej dla  $k$ -tej zmiennej wyjściowej ma postać

$$\min_{\Delta x, y_k^{ds}} J_k^{sy} = \delta_k (y_k^n - y_k^s - y_k^{ds})^2$$

przy ograniczeniach

$$-\tau_k^{sy} \leq y_k^{ds} \leq \tau_k^{sy}$$

Zadanie optymalizacji (8.7) może być zatem sformułowane w postaci zadania LQ (8.8)

$$\begin{aligned}
& \min_{\Delta x, x^{dlp}, x^{dln}, x^{ds}, y^{dlp}, y^{dln}, y^{ds}} \left\{ \sum_{k=1}^{nx} \left[ \alpha_k \left( x_k^{dlp} + x_k^{dln} \right) + \right. \right. \\
& \quad \left. \left. + \beta_k \left( x_k^a + \Delta x_k - x_k^s - x_k^{ds} \right)^2 \right] + \right. \\
& \quad \left. + \sum_{k=1}^{ny} \left[ \gamma_k \left( y_k^{dlp} + y_k^{dln} \right) + \delta_k \left( y_k^a + \Delta x K_k - y_k^s - y_k^{ds} \right)^2 \right] \right\} \quad (8.8)
\end{aligned}$$

przy ograniczeniach

$$\begin{aligned}
x_k^{dlp} &\geq x_k^a + \Delta x_k - x_k^s - \tau_k^{lx}, \\
x_k^{dlp} &\geq 0, \\
x_k^{dln} &\geq x_k^s - x_k^a + \Delta x_k - \tau_k^{lx}, \\
x_k^{dln} &\geq 0, \\
-\tau_k^{sx} &\leq x_k^{ds} \leq \tau_k^{sx}, \\
-\tau_k^{sy} &\leq y_k^{ds} \leq \tau_k^{sy}, \\
y_k^{dlp} &\geq y_k^a + \Delta x K_k - y_k^s - \tau_k^{ly}, \\
y_k^{dlp} &\geq 0, \\
y_k^{dln} &\geq y_k^s - y_k^a - \Delta x K_k - \tau_k^{ly}, \\
y_k^{dln} &\geq 0, \\
z_{low} &\leq \Delta x \leq z_{hi}, \\
u_{low} &\leq x^a + \Delta x \leq u_{hi}.
\end{aligned}$$

Powyższa postać zadania optymalizacji nie uwzględnia nierównościowych *twardych* ograniczeń na wyjścia procesu. W praktycznych zastosowaniach w SILO ogranicza się wyjścia procesu w sposób *miękkki*, poprzez odpowiednie zdefiniowanie kary dla wybranego wyjścia procesu. Kara dla każdego punktu składa się z członu liniowego i kwadratowego, dzięki czemu można tak ukształtować zewnętrzną funkcję kary, że człon kwadratowy będzie aktywowany w okolicy niepożądanych wartości wybranego sygnału. Uwzględnienie twardych ograniczeń na wyjścia procesu jest jednak możliwe w warstwie optymalizacji na modelu globalnym i mieszanym, choć nie jest używane w rzeczywistych wdrożeniach. Zostanie ono przedstawione dla zachowania ogólności opisu. Należy jednak pamiętać, że ze względu na niedokładności modelu twarde ograniczenie wyjść obiektu może nie być spełnione. Ponadto stosując twarde ograniczenia

istnieje ryzyko, że nie będzie istniało rozwiązanie zadania LQ. Aby uwzględnić twarde ograniczenia wyjść obiektu, do zadania optymalizacji (8.8) należy dodać ograniczenie

$$t_{low} \leq y_k^a + \Delta x K_k \leq t_{hi}.$$

Wykorzystanie macierzy modelu bezpiecznego w zadaniu identyfikacji modelu (8.4) zapewnia, że zadanie to jest dobrze uwarunkowane. Należy jednak zauważyć, że w przypadku gdy macierz  $W$  jest osobliwa, wówczas macierz  $K$  może nie odzwierciedlać rzeczywistych wzmocnień obiektu regulacji. W algorytmie optymalizacji w warstwie optymalizacji na modelu lokalnym i globalnym zaimplementowano więc tzw. *algorytm blokowania zmiennych*. Jego zadaniem jest dbanie o to aby macierz  $W$  była nieosobliwa, a co za tym idzie aby zadanie (8.4) było dobrze uwarunkowane.

W każdym kroku optymalizacji wykonywanym w warstwie optymalizacji na modelu mieszanym lub w warstwie optymalizacji na modelu globalnym, sprawdzane jest czy zadanie identyfikacji modelu procesu, nie uwzględniające modelu bezpiecznego (8.3), jest dobrze uwarunkowane. Stopień uwarunkowania wyrażony jest w następujący sposób

$$cond(W) = \|W^{-1}\| \|W\|$$

W przypadku zastosowania normy spektralnej stopień uwarunkowania może być wyrażony w następujący sposób

$$c = \|W^{-1}\|_2 \|W\|_2 = \frac{\sigma_{max}}{\sigma_{min}}$$

Sprawdzenie uwarunkowania zadania identyfikacji modelu dokonywane jest zatem na podstawie badania stosunku największej  $\sigma_{max}$  i najmniejszej  $\sigma_{min}$  wartości szczególnej macierzy  $W$ . Parametr  $c$  określa stopień uwarunkowania równania normalnego (8.3). W przypadku gdy wartość parametru  $c$  jest równa jedności, wówczas równanie (8.3) jest dobrze uwarunkowane. Im większa wartość parametru  $c$ , tym równanie (8.3) jest gorzej uwarunkowane. Jednym z parametrów algorytmu optymalizacji jest więc graniczna wartość parametru  $c$ , przy której zakłada się, że równanie (8.3) jest dobrze uwarunkowane. W przypadku, gdy wartość współczynnika  $c$  będzie wyższa niż zakładana wartość graniczna, wówczas uruchamiany jest mechanizm blokowania zmiennych. Należy zauważyć, że macierz  $W$  jest macierzą symetryczną dodatnio półokreśloną. Zachodzi więc następująca równość:

$$\sigma_i = \sqrt{\lambda_i}, \lambda_i \in Spect(W), i = 1, 2, \dots, nx$$

Tak więc wyznaczenie wartości szczególnych macierzy  $W$ , polega na wyznaczeniu wartości własnych  $\lambda$  tej macierzy. W tym celu wykorzystuje się metodę QR polegającą na sukcesywnym wykorzystywaniu rozkładu QR macierzy  $W$ . Aby zmniejszyć nakład obliczeniowy metody, macierz  $W$  jest na początku sprowadzana do postaci trójdiagonalnej.


Mechanizm blokowania zmiennych polega na blokowaniu pewnej ilości zmiennych sterujących w danych kroku optymalizacji. Zmienne sterujące, które mają być zablokowane losowane są z pewnym rozkładem prawdopodobieństwa. Tak więc w wyniku operacji blokowania rozmiar zadania optymalizacji zostaje zredukowany. Powoduje to mutacje w nowych limfocytach typu B, powstałych w wyniku podania do obiektu wektora sterowań, będącego rozwiązaniem zredukowanego zadania optymalizacji. Głównym celem tego mechanizmu jest eliminacja potencjalnych liniowych zależności między kolumnami macierzy obserwacji, zbudowanymi na podstawie limfocytów typu B. Eliminacja wspomnianych liniowych zależności prowadzi do tego, że równanie (8.4) jest lepiej uwarunkowane a macierz  $K$  dokładniej reprezentuje wzmocnienia modelu w okolicy aktualnego punktu pracy.

Potencjalne liniowe zależności w macierzach obserwacji  $\Delta X_L$  i  $\Delta X_G$  mogą na przykład wynikać z tego, że w każdym kroku optymalizacji na modelu, wartość elementu wektora sterowań  $x_i$  i  $x_j$  zmieniana jest według jednej z dwóch poniższych reguł:

$$R^1 = \begin{cases} x_i^{new} = x_i^{old} + \Delta^{max} x_i; \\ x_j^{new} = x_j^{old} - \Delta^{max} x_j. \end{cases}$$

$$R^2 = \begin{cases} x_i^{new} = x_i^{old} - \Delta^{max} x_i; \\ x_j^{new} = x_j^{old} + \Delta^{max} x_j. \end{cases}$$

gdzie  $\Delta^{max} x_k$  oznacza maksymalny bezwzględny przyrost wartości  $k$ -tego elementu wektora  $x$ . W takim przypadku, w macierzach  $\Delta X_L$  i  $\Delta X_G$  zaczną pojawiać się liniowe zależności między  $i$ -tą kolumną reprezentującą  $i$ -ty element wektora sterowań i  $j$ -tą kolumną reprezentującą  $j$ -ty element wektora sterowań. Przedstawiona sytuacja jest często obserwowana podczas rzeczywistych wdrożeń systemu SILO, gdy zdefiniuje się wąskie ograniczenia na przyrost  $i$ -tego oraz  $j$ -tego elementu wektora sterowań w pojedynczym kroku optymalizacji. Zaprezentowana metoda blokowania zmiennych powoduje, że ewentualne liniowe zależności są eliminowane, co przekłada się na dokładność wyznaczenia wartości wzmocnień modelu używanego przez SILO podczas optymalizacji.

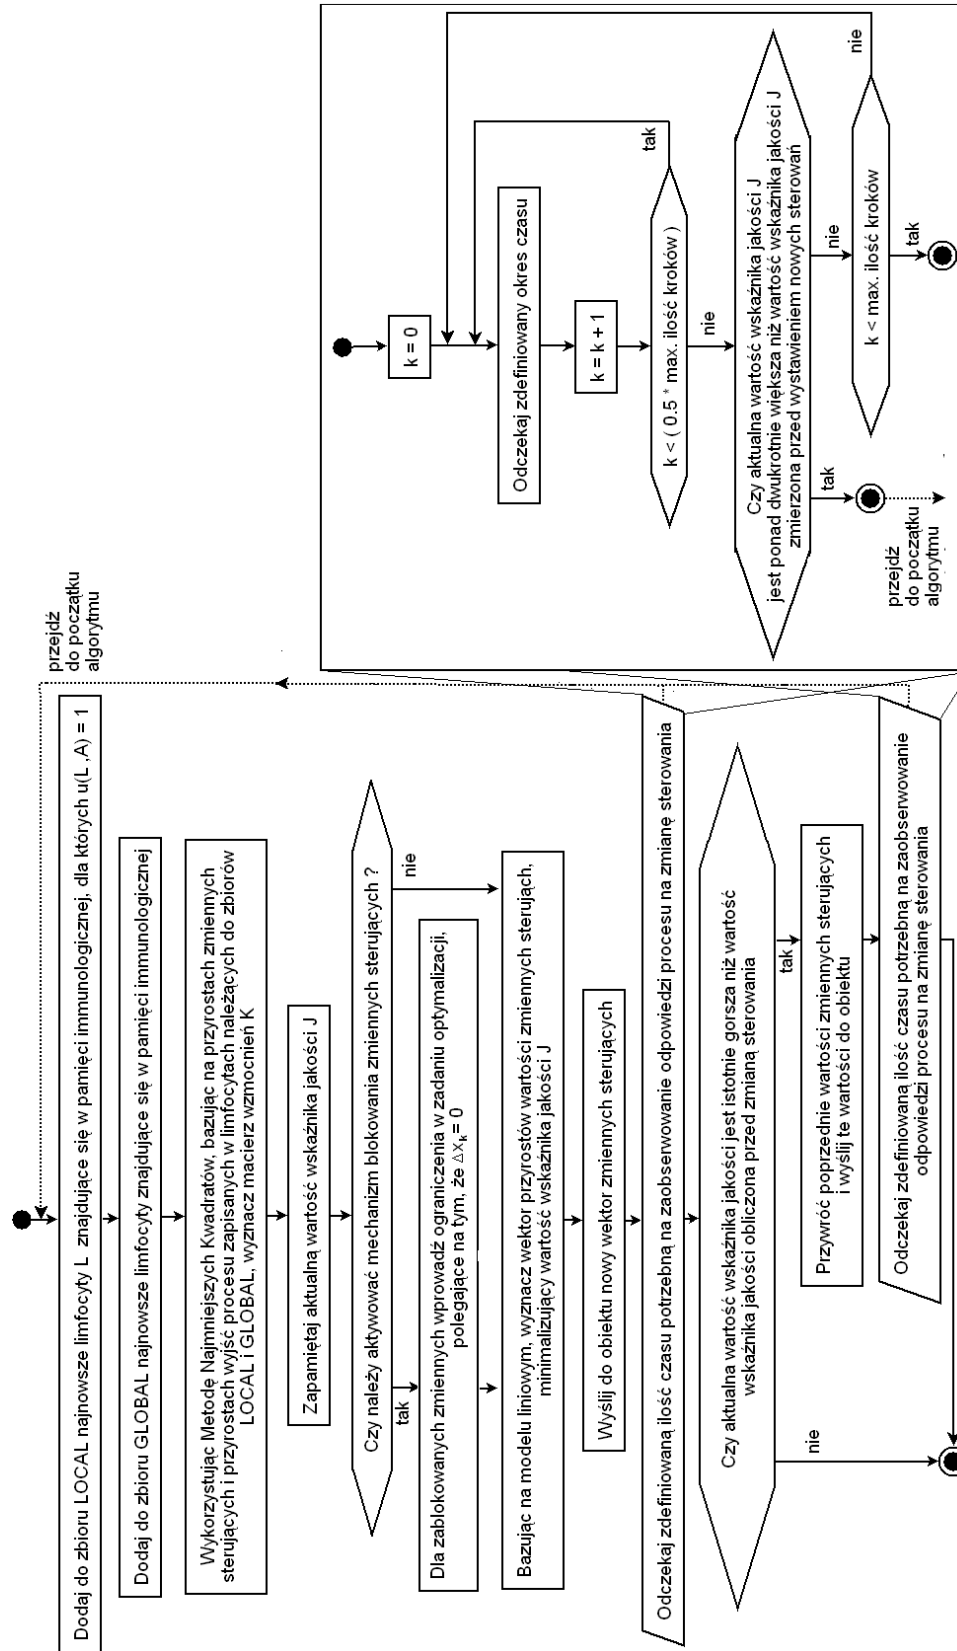


Rysunek 8.4 a) Przykładowa trajektoria sterowań, gdy mechanizm blokowania jest wyłączony, b) przykładowa trajektoria sterowań, gdy mechanizm blokowania jest włączony i uruchamiany w każdym kroku optymalizacji.

Na rys. 8.4 a) Przedstawiono sytuację uzyskaną podczas symulacji, w której zmienne sterujące reprezentujące poziom tlenu (O<sub>2</sub> PROC) i położenie lewej kłapy powietrza wtórnego (DAMPER LEFT) są ze sobą skorelowane. Może to doprowadzić, do sytuacji, w której macierz  $W$  będzie osobliwa. Na rys. 8.4 b) pokazano, że stosując mechanizm blokowania zmiennych eliminuje się liniową zależność wymienionych sygnałów, jednak odbywa się to kosztem jakości uzyskanego rozwiązania. W przypadku zastosowania mechanizmu blokowania zmiennych, jeden z minimalizowanych sygnałów wyjściowych (emisja CO) osiągnął wyższą wartość, niż w przypadku gdy nie stosowano tego mechanizmu. Należy jednak pamiętać, że chwilowe odstępianie od warunków ścisłej optymalności jest uzasadnione, ze względu na konieczność dbania o to aby macierz  $K$  odzwierciedlała rzeczywiste wzmocnienia obiektu, a zadanie (8.4) było dobrze uwarunkowane.

Algorytm użyty w warstwie optymalizacji na modelu mieszanym został przedstawiony na rys. 8.5. Pierwszą czynnością wykonywaną w warstwie optymalizacji na modelu jest wyselekcjonowanie odpowiednich limfocytów i budowa modelu mieszanego. Do stworzenia tego modelu system SILO wykorzystuje informacje zgromadzone w  $l$  najmłodszych limfocytach *lokalnych* i  $g$  najmłodszych limfocytach *globalnych*. Następnie na podstawie wartości współczynnika  $c$  podejmowana jest decyzja o blokowaniu pewnej ilości zmiennych sterujących. Kolejnym krokiem jest obliczenie wektora przyrostów sterowań minimalizującego wskaźnik jakości  $J$  (patrz równanie (8.8)). Po wysłaniu nowego sterowania do obiektu i odczekaniu okresu optymalizacji sprawdzane jest czy wartość wskaźnika jakości pogorszyła się istotnie w stosunku do wartości wskaźnika jakości zmierzonej przed zmianą sterowania. Znaczenie wyrażenia *istotne pogorszenie* określa parametr definiowany przez użytkownika. Użytkownik definiuje graniczną wartość stosunku wartości wskaźnika jakości po i przez zmianą sterowania, powyżej której zakłada się, że wskaźnik jakości uległ istotnemu pogorszeniu. Jeżeli wskaźnik jakości uległ istotnemu pogorszeniu następuje przywrócenie wartości elementów wektora  $x$ , zmierzonych przed zmianą sterowania. Jeżeli wartość wskaźnika jakości wzrosła w sposób nieistotny lub zmalała, wówczas następuje wyjście z warstwy optymalizacji na modelu mieszanym. Algorytm przełączania między warstwami może wówczas ponownie wybrać warstwę optymalizacji na modelu mieszanym lub inną dostępną warstwę. Przywracanie stanu wektora  $x$  jaki występował przed zmianą sterowania, w przypadku gdy wskaźnik jakości pogorszył się tylko nieznacznie, jest





Rysunek 8.5 Algorytm warstwy optymalizacji na modelu mieszanym.

stratą cennego czasu, który można wykorzystać na poszukiwanie lepszego rozwiązania w sposób niedeterministyczny w warstwie optymalizacji stochastycznej.

W przedstawionym algorytmie, podczas oczekiwania na ustalenie się odpowiedzi obiektu (czas zdefiniowany przez okres optymalizacji) sprawdzane jest, czy wskaźnik jakości nie pogorszył się dwukrotnie po upływie co najmniej połowy okresu optymalizacji. Jeżeli takie pogorszenie nastąpiło, wówczas następuje natychmiastowy powrót do początku algorytmu. Takie pogorszenie najczęściej jest wynikiem niekorzystnej zmiany wartości elementów wektora zakłóceń. Uzasadnione jest więc wstrzymanie wykonywania algorytmu i powrót do etapu poszukiwania limfocytów, które reprezentują podobny stan procesu do aktualnego. Wówczas model użyty w zadaniu optymalizacji będzie reprezentował zachowanie obiektu w otoczeniu nowego punktu pracy.

Analizując działanie warstwy optymalizacji na modelu mieszanym widać wyraźną analogię do wtórnej odpowiedzi immunologicznej. System SILO, w warstwie optymalizacji na modelu mieszanym, wykorzystuje wiedzę zawartą w limfocytach typu B, znajdujących się w pamięci immunologicznej, do szybkiej eliminacji patogenu. Analogiczne działanie wykazuje układ odpornościowy podczas wtórnej odpowiedzi immunologicznej.

## 8.2 Warstwa optymalizacji na modelu globalnym

Algorytm używany przez warstwę optymalizacji na modelu globalnym jest bardzo podobny do algorytmu używanego w warstwie optymalizacji na modelu mieszanym. Jedyna różnica polega na tym, że w warstwie optymalizacji na modelu globalnym używany jest model zbudowany jedynie na podstawie limfocytów globalnych. Informacja zawarta w zbiorze limfocytów lokalnych nie jest wykorzystywana. Wynika to z faktu, że warstwa optymalizacji na modelu globalnym wykonywana jest w sytuacji, w której nie jest możliwe znalezienie wystarczającej liczby limfocytów lokalnych, reprezentujących podobny do aktualnego punkt pracy.

W opisywanej warstwie system SILO nie dysponuje wystarczającą wiedzą na temat statycznych zależności procesu w okolicy aktualnego punktu pracy. Dostępna jest natomiast wiedza o procesie zebrana w sytuacji, gdy proces znajdował się w innych punktach pracy niż aktualny. Wiedza ta wykorzystywana jest do budowy liniowego

modelu postaci (8.2). Należy pamiętać, że jest to tylko liniowa aproksymacja nieliniowego zjawiska, która nie jest wykonana w okolicy aktualnego punktu pracy. Model nie jest więc tak dokładny jak ten używany w warstwie optymalizacji na modelu mieszanym. Niemniej jednak model ten agreguje pewne podstawowe zależności istniejące w procesie. Znając te podstawowe zależności SILO może próbować zmniejszyć wartość wskaźnika jakości.

### 8.3 Warstwa optymalizacji stochastycznej

W początkowej fazie działania systemu SILO rozmiar pamięci immunologicznej jest relatywnie mały. Stosując analogię do systemu odpornościowego można powiedzieć, że system jest często atakowany przez niezarejestrowane i nieznanne patogeny. SILO nie posiada wystarczającej wiedzy, aby móc zbudować modele matematyczne i na ich podstawie postarać się zmniejszyć wartość wskaźnika jakości. Głównym celem tej warstwy jest więc nauka procesu. Specjalna heurystyka używana w tej warstwie została zaprojektowana w taki sposób aby uwzględnić następujące cele:

- Naukę procesu, poprzez wykonywanie automatycznych testów parametrycznych w okolicy aktualnego punktu pracy. Na podstawie wykonywanych testów moduł uczący generuje nowe limfocyty B;
- Zmniejszenie wartości wskaźnika jakości w długim okresie czasu, przy założeniu, że zakłócenia oddziałujące na proces nie zmieniają się istotnie w długim okresie czasu. Stosując analogię do układu odpornościowego można powiedzieć, że celem tej warstwy jest wyeliminowanie patogenu w długim okresie czasu, przy założeniu, że system jest atakowany cały czas przez ten sam patogen;
- Dbanie o to, aby macierze obserwacji powstałe z limfocytów w warstwie optymalizacji na modelu globalnym i mieszanym (macierze  $\Delta X_L$  i  $\Delta X_G$ ) były nieosobliwe, przez co również zadanie identyfikacji modelu (8.4) było dobrze uwarunkowane.

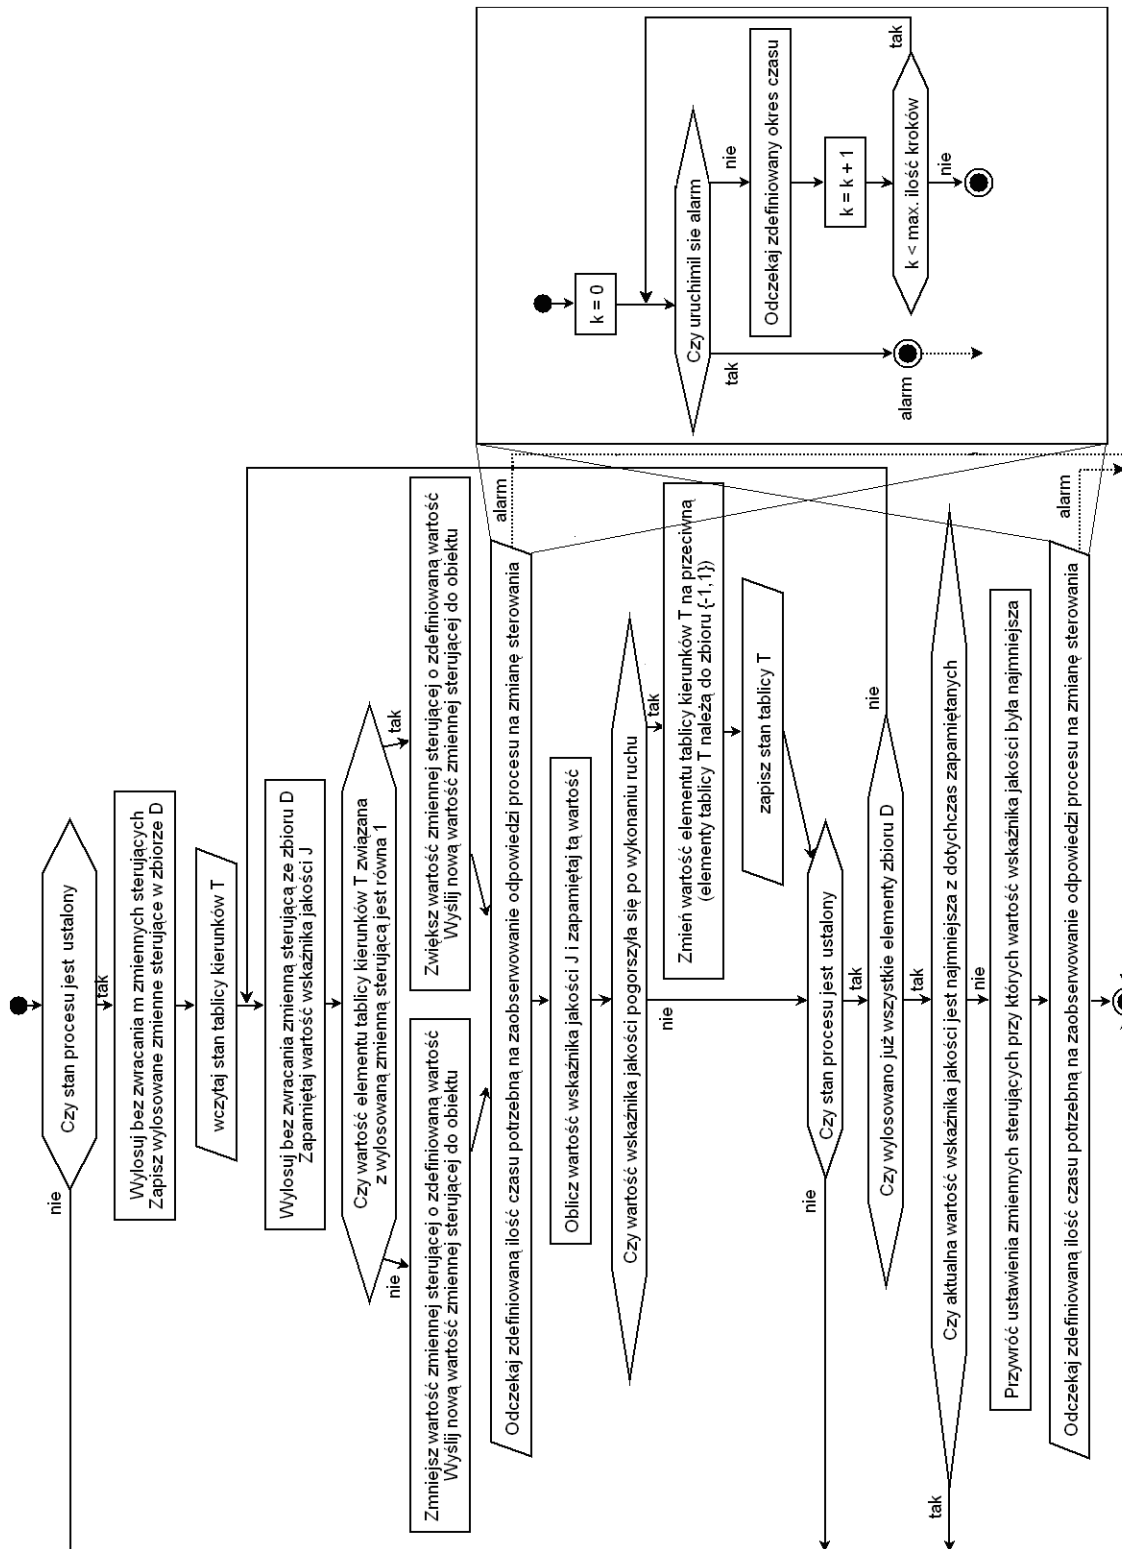
Mając na uwadze powyższe cele stworzono heurystykę, w której w każdym kroku optymalizacji wybiera się zmienną sterującą (element wektora  $x$ ) i zadaje się na tą zmienną skok jednostkowy o zdefiniowanej przez użytkownika wartości. W wyniku zmiany elementu wektora  $x$ , następuje zmiana wyjść procesu. Na podstawie takiego testu moduł uczący tworzy limfocyt typu B. W kolejnym kroku optymalizacji wybierany jest losowo inny element wektora  $x$  i wykonywany jest kolejny test. Po wykonaniu

założonej ilości testów wybiera się taką konfigurację zmiennych sterujących, przy której wskaźnik jakości przyjmował najmniejszą wartość. Heurystyka wykorzystywana w warstwie optymalizacji stochastycznej została szczegółowo zaprezentowana na rys. 8.6. Heurystyka ta powstała w oparciu o eksperymenty przeprowadzone w jednej z polskich elektrowni.

W warstwie optymalizacji stochastycznej, po sprawdzeniu czy stan procesu jest ustalony, losowane jest bez zwracania  $m$  zmiennych sterujących. Zmienne te zapisywane są w zbiorze  $D$ . Rozkład prawdopodobieństwa według jakiego następuje losowanie zmiennych, określa użytkownik. Najczęściej przyjmuje się, że jest to dyskretny rozkład jednostajny. Następnie następuje wczytanie tablicy kierunków. Przy pierwszym uruchomieniu tablica kierunków jest zainicjalizowana wartościami  $-1$ . W kolejnym kroku ze zbioru  $D$  losowana jest bez zwracania jedna zmienna sterująca. Wartość wskaźnika jakości zostaje zapamiętana. Następnie następuje zmiana wartości wylosowanej zmiennej sterującej o zdefiniowaną przez użytkownika bezwzględną wartość skoku jednostkowego. Wartość zmiennej sterującej zostaje zmniejszona lub zwiększona w zależności od informacji z tablicy kierunków. Po odczekaniu okresu optymalizacji sprawdzana jest wartość wskaźnika jakości. Jeżeli wartość wskaźnika jakości zwiększyła się po wykonaniu testu, znak elementu tablicy kierunków, związany z wylosowaną zmienną jest odwracany. W przeciwnym przypadku znak elementu w tablicy kierunków nie zmienia się. Jeżeli po wykonaniu testu stan procesu jest nadal ustalony, wylosowywana jest bez zwracania kolejna zmienna sterująca ze zbioru  $D$  i wykonywany jest kolejny test.

W trakcie wykonywania testu sprawdzane jest, czy nie zaistniały warunki, które powodują konieczność zaprzestania wykonywania testów. Warunki te nazywane *alarmami* są definiowane przez użytkownika i związane są z bezpieczeństwem i efektywną pracą obiektu. W przypadku procesu spalania w kotle energetycznym alarm może być aktywowany w przypadku zbyt wysokiej emisji CO.

Po wykonaniu testów na wszystkich elementach zbioru  $D$ , następuje sprawdzenie, czy podczas tych testów wystąpiła konfiguracja zmiennych sterujących, dla której wartość wskaźnika jakości przyjmowała mniejszą wartość niż aktualna. W przypadku wykrycia takiej sytuacji, system SILO przywraca najlepszą zapamiętaną w czasie wykonanych testów konfigurację wektora  $x$ . Następnie następuje opuszczenie warstwy optymalizacji stochastycznej i przejście do innej warstwy lub ponowne wykonanie



Rysunek 8.6 Algorytm warstwy optymalizacji stochastycznej.

heurystyki z warstwy optymalizacji stochastycznej. Decyduje o tym algorytm przełączania między warstwami. Wykonanie algorytmu przedstawionego na rys. 8.6 nazywa się *cyklem testowym*.

Przedstawiona heurystyka zapewnia, że system SILO jest w stanie zdobyć wiedzę o procesie w nowym punkcie pracy. Zmiana tylko jednej zmiennej sterującej w jednym kroku optymalizacji powoduje, że:

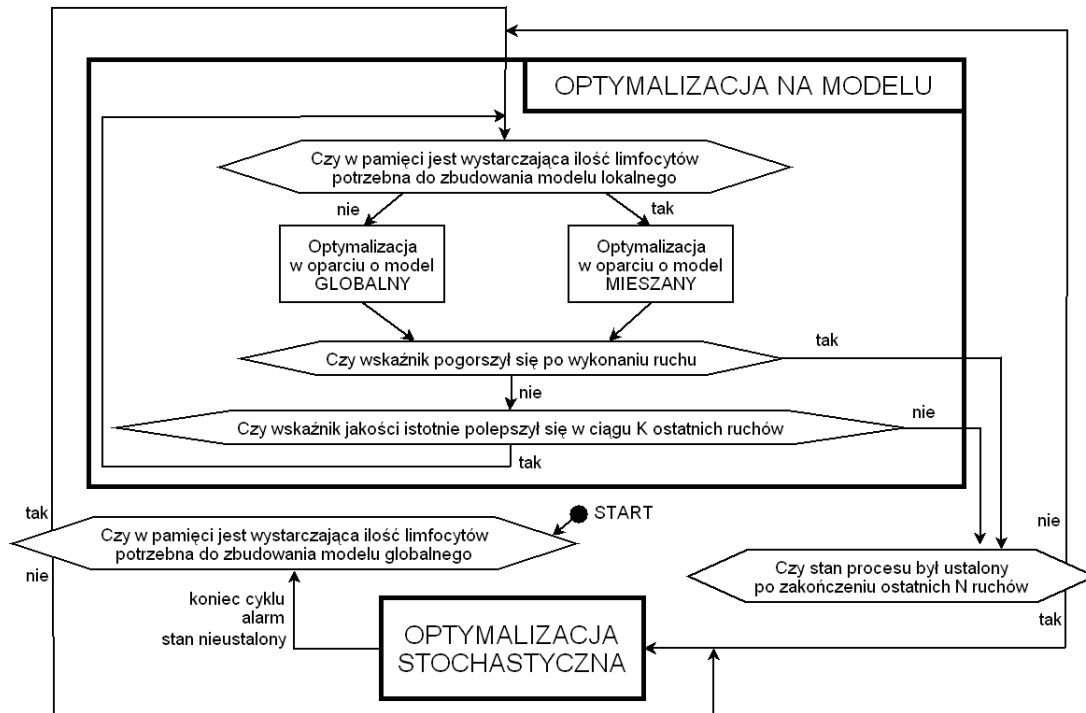
- wiedza zgromadzona w oparciu o wykonane testy jest dokładniejsza;
- macierz  $X_L$  i  $X_G$  używana w zadaniu identyfikacji modelu jest nieosobliwa, gdyż jednorazowe zmiany za ledwie jednego elementu wektora  $x$  powodują, że kolumny macierzy nie są liniowo od siebie zależne.

Ponadto przedstawiona heurystyka umożliwia zmniejszenie wartości wskaźnika jakości w długim okresie czasu. Analizując działanie warstwy optymalizacji stochastycznej widać wyraźną analogię do pierwotnej odpowiedzi immunologicznej. W trakcie pierwotnej odpowiedzi immunologicznej układ odpornościowy walczy z nowym, niezarejestrowanym patogenem. Organizm potrzebuje relatywnie dużo czasu aby zwalczyć nieznaną patogen. Po udanej akcji obronnej wiedza o patogenie jest zapamiętywana. Jest ona później wykorzystywana podczas wtórnej odpowiedzi immunologicznej do skutecznej i szybkiej obrony przed podobnymi patogenami. Analogicznie w systemie SILO wiedza zdobyta w warstwie optymalizacji stochastycznej jest wykorzystywana w pozostałych warstwach.

Przedstawiona warstwa jest w istocie warstwą identyfikacji obiektu regulacji. Jej podstawowe zadanie jest analogiczne do zadania stojącego przed inżynierami wykonywującymi testy identyfikacyjne podczas wdrożenia regulatora predykcyjnego z przesuwającym horyzontem. Należy jednak mieć na uwadze, że w systemie SILO testy te są wykonywane automatycznie, a jednym z zadań stochastycznej heurystyki zaimplementowanej w omawianej warstwie jest realizacja założonych celów optymalizacji. Ponadto trzeba pamiętać, że wiedza na temat obiektu regulacji gromadzona jest także wówczas, gdy moduł optymalizacji znajduje się w jednej z dwóch warstw bazujących na modelu obiektu.

## 8.4 Algorytm przełączania między warstwami

Algorytm przełączający moduł optymalizacji między warstwami przedstawionymi na rys. 8.7 jest kluczowym mechanizmem zapewniającym sprawne funkcjonowanie systemu SILO. Heurystyka przełączania warstw opiera się na zasadzie, że należy wykorzystywać wiedzę SILO na temat procesu w aktualnym punkcie pracy (warstwa optymalizacji na modelu mieszanym). Jeżeli wiedza ta jest niewystarczająca, wówczas system SILO wykorzystuje wiedzę na temat podstawowych, ogólnych zależności rządzących procesem (warstwa optymalizacji na modelu globalnym). Jeżeli optymalizacja przeprowadzona w oparciu o tę wiedzę okaże się nieskuteczna, wówczas należy poszukiwać optymalnego rozwiązania korzystając z warstwy optymalizacji stochastycznej.



Rysunek 8.7 Algorytm przełączania warstw.

Po uruchomieniu systemu SILO algorytm przełączania między warstwami sprawdza, czy w pamięci immunologicznej istnieje wystarczająca ilość limfocytów potrzebnych do budowy modelu globalnego. Jeżeli nie, oznacza to że system SILO znajduje się we wstępnym etapie zdobywania wiedzy o procesie. Sterowania wyznaczone są w

oparciu o heurystykę zaimplementowaną w warstwie optymalizacji stochastycznej. Z czasem w wyniku testów przeprowadzonych w warstwie optymalizacji stochastycznej, w pamięci immunologicznej powstanie wystarczająco dużo limfocytów aby na ich podstawie zbudować model matematyczny. Wówczas następuje przełączenie do warstwy optymalizacji na modelu matematycznym. Jeżeli w pamięci immunologicznej jest wystarczająca liczba limfocytów reprezentujących podobny do aktualnego punkt pracy, to automatycznie konstruowany jest model mieszany. W przeciwnym przypadku konstruowany jest model globalny. W oparciu o model dokonywana jest optymalizacja wskaźnika jakości. Jeżeli po zmianie wektora sterowań  $x$  i odczekaniu okresu optymalizacji wskaźnik jakości pogorszy się, oznacza to że użyty model nie jest wystarczająco dokładny. Na jego podstawie nie można znaleźć lepszego rozwiązania. W takim przypadku należy pogłębić wiedzę na temat procesu i spróbować znaleźć lepsze rozwiązanie w sposób niedeterministyczny w warstwie optymalizacji stochastycznej. Pogorszenie wskaźnika jakości nie musi wynikać z niewłaściwej zmiany wektora sterowań. Przyczyną pogorszenia wskaźnika jakości może także być zmiana wektora zakłóceń  $z$ . W takim przypadku przejście do warstwy optymalizacji stochastycznej nie jest wskazane z dwóch powodów:

- Do przeprowadzenia wiarygodnych testów i nauki procesu wymagane jest aby stan procesu był ustalony;
- Podczas zmian wektora  $z$  sprawą najważniejszą jest szybkie uwzględnienie tych zmian i sprawna reakcja na te zmiany. Aby móc szybko zareagować na zmiany wektora zakłóceń niezbędna jest wiedza o procesie agregowana w postaci modelu.

Widać więc, że w przypadku zmiany wektora zakłóceń najlepszą strategią jest pozostanie w warstwie optymalizacji na modelu mieszanym lub globalnym. W takiej sytuacji algorytm przełączania między warstwami nie pozwoli na przekazanie sterowania do warstwy optymalizacji stochastycznej, ze względu na fakt, że moduł analizatora stanu nie wykrył stanu ustalonego podczas  $N$  ostatnich okresów optymalizacji. Tak więc moduł optymalizacji pozostanie w warstwie optymalizacji na modelu mieszanym lub globalnym.

Po wykonaniu algorytmu zaimplementowanego w warstwie optymalizacji na modelu mieszanym (patrz rys. 8.5) lub globalnym sprawdzane jest czy w czasie ostatnich  $K$  okresów optymalizacji wskaźnik jakości istotnie się polepszył. Jeżeli w ciągu ostatnich  $K$  kroków następowało jedynie nieznaczne polepszenie wskaźnika jakości,



wówczas następuje przejście do warstwy optymalizacji stochastycznej. Mechanizm ten wprowadzono po to aby przyspieszyć proces odnajdywania optymalnego rozwiązania używając do tego celu heurystyki z warstwy optymalizacji stochastycznej. Ponadto mała poprawa wskaźnika jakości może oznaczać, że system SILO wystawia w każdym kroku optymalizacji małe przyrosty sterowań. Moduł uczenia nie tworzy limfocytów na podstawie zmian wektora sterowań, które są mniejsze niż pewna zdefiniowana przez użytkownika wartość. Wynika to z dbałości o jakość tworzonych limfocytów. Tak więc jeżeli istnieje obawa, że przyrosty sterowań wystawiane przez SILO są małe, to istnieje także niebezpieczeństwo, że moduł uczenia nie tworzy nowych limfocytów. Istotą SILO jest nauka procesu i adaptacja do nowych warunków. Opisana sytuacja grozi tym, że system SILO przestanie przez pewien czas zdobywać nową wiedzę. Dlatego też sytuacja taka jest wykrywana i sterowanie przełączane jest do warstwy optymalizacji stochastycznej. Jeżeli w warstwie tej zostanie znalezione lepsze rozwiązanie, wówczas jest ono punktem startowym dla optymalizacji przeprowadzanej w warstwach korzystających z modelu. Optymalizacja stochastyczna przerywana jest, gdy:

- po zakończeniu okresu optymalizacji zostanie wykryty stan nieustalony;
- wystąpi jeden ze zdefiniowanych alarmów (np: zbyt wysoka emisja CO w przypadku procesu spalania).

Algorytm przełączania między warstwami powstał w wyniku eksperymentów i obserwacji prowadzonych w elektrowniach omówionych w rozdziale 11.

Obrazowym podsumowaniem głównej idei przedstawionego w niniejszym rozdziale warstwowego algorytmu optymalizacji jest porównanie tego algorytmu do zachowania operatora procesu przemysłowego. Załóżmy, że zadanie nadzorowania procesu przypadło nowemu operatorowi, który nie ma wiedzy na temat regulowanego obiektu. Nowy operator będzie poznawał proces poprzez pojedyncze zmiany zmiennych sterujących i obserwacje odpowiedzi obiektu na te zmiany. Jednocześnie operator będzie wykorzystywał zdobytą wiedzę do zadawania sterowań, które pozwolą na realizację założonych celów (dotyczących na przykład wydajności procesu lub spełnienia norm emisji szkodliwych związków do atmosfery). Operator poznając proces będzie zmieniał sterowania w taki sposób aby móc poznać obiekt przez obserwacje odpowiedzi obiektu na pojedyncze zmiany jednego elementu wektora sterowania i jednocześnie kierunek pojedynczych zmian sterowania będzie tak dobrany, aby dążyć do realizacji założonych celów regulacji. Widać zatem, że ten początkowy etap pracy operatora odpowiada heurystyce zaimplementowanej w warstwie optymalizacji stochastycznej.

Po pewnym czasie operator na tyle pozna proces, że będzie w stanie dokonać syntezy zdobytej wiedzy. Wykorzystując naturalną zdolność człowieka do syntezy i generalizacji wiedzy, operator będzie w stanie przewidzieć, jaki wpływ na proces, przy danych zakłóceniach oddziałujących na proces, będzie miała jednoczesna zmiana kilku zmiennych sterujących. Dzięki temu operator będzie w stanie skuteczniej kompensować zakłócenia i dążyć do realizacji założonych celów. Należy zwrócić uwagę, że operator uwzględnia fakt, że zachowanie obiektu może być różne w różnych punktach pracy i dlatego do przewidywania odpowiedzi obiektu wykorzystuje wiedzę i doświadczenie zdobyte w sytuacji gdy obiekt znajdował się w podobnym punkcie pracy do aktualnego. Jednocześnie operator obserwuje, że z czasem charakterystyki obiektu zmieniają się, dlatego większe znaczenie ma najbardziej aktualna wiedza o zachowaniu obiektu w okolicy aktualnego punktu pracy. Należy podkreślić, że obserwując odpowiedzi obiektu na jednoczesne zmiany wielu elementów wektora sterowań operator zdobywa wiedzę o obiekcie. Przedstawione rozumowanie odpowiada algorytmowi zaimplementowanemu w warstwie optymalizacji na modelu mieszanym.

Doświadczony operator, potrafiący dobrze przewidzieć zachowanie obiektu w okolicy aktualnego punktu pracy, jest w stanie osiągnąć rozwiązanie bliskie punktu optymalnego w relatywnie krótkim czasie (w relatywnie małej ilości kroków, polegających na zmianach wektora sterowań). Załóżmy, że operator znalazł rozwiązanie bliskie punktu optymalnego i nie jest już w stanie znaleźć lepszego rozwiązania w oparciu o posiadaną wiedzę i doświadczenie. Jego prognozy co do przyszłego zachowania obiektu przestają się sprawdzać. Wówczas dociekliwy operator może zacząć poszukiwać lepszego rozwiązania poprzez pojedyncze, niewielkie zmiany poszczególnych elementów wektora sterowań. Jeżeli kierunek zmian powoduje lepsze zrealizowanie założonych celów regulacji, wówczas operator będzie modyfikował wybrany element wektora sterowań w taki sposób aby zachować pożądaną kierunek zmian. Jednocześnie będzie wybierał i modyfikował również inne elementy wektora sterowań. Zachowanie operatora będzie charakteryzowała pewna losowość w doborze zmiennych sterujących, natomiast będzie on starał się modyfikować kierunek zmian wektora sterowań w zależności od obserwowanego gradientu spełnienia założonych celów regulacji. Wykonując pojedyncze zmiany sterowań i obserwując odpowiedzi obiektu na te zmiany, operator będzie uaktualniał swoją wiedzę o obiekcie regulacji. Dzięki temu będzie w stanie ponownie dokonać syntezy posiadanej wiedzy, zawierającej również najbardziej aktualne obserwacje. Na podstawie tej wiedzy operator będzie w stanie dokładniej przewidzieć

zachowanie obiektu i być może, uwzględniając wewnętrzne zależności między wejściami i wyjściami procesu, uda mu się znaleźć jeszcze lepsze rozwiązanie. Powyższe rozważania mają swoje odzwierciedlenie w systemie SILO. Rozpatrywana sytuacja odpowiada przełączeniu modułu optymalizacji z warstwy optymalizacji na modelu mieszanym do warstwy optymalizacji stochastycznej, wykonaniu cyklu testowego w warstwie optymalizacji stochastycznej, a następnie ponownym przejściu do warstwy optymalizacji na modelu mieszanym.

Założmy, że operator potrafi dobrze przewidzieć zachowanie obiektu w typowych punktach pracy. Rozpatrzmy sytuację, w której na skutek zmiany wektora zakłóceń obiekt przeszedł do nowego punktu pracy. Operator nie ma wiedzy o zachowaniu obiektu w okolicy nowego punktu pracy, dlatego też będzie na początku zakładał, że jakościowy charakter zależności między wejściami i wyjściami procesu jest podobny jak w innych punktach pracy. W oparciu o to założenie operator dokona syntezy najbardziej aktualnej wiedzy reprezentującej zachowanie obiektu w różnych punktach pracy. Na jej podstawie będzie starał się przewidzieć przyszłe zachowanie obiektu w okolicy aktualnego punktu pracy. Wraz ze zbliżaniem się do rozwiązania optymalnego, prognozy operatora będą musiały być coraz bardziej dokładne. Może się zdarzyć, że operator nie będzie mógł już poprawić rozwiązania w oparciu o predykcję wyjść wielowymiarowego obiektu i będzie zmuszony szukać lepszego rozwiązania, dokonując pojedynczych zmian poszczególnych elementów wektora sterowań. Zmiany te będą charakteryzować się pewną losowością. Niezależnie od tego, czy to działanie przyniesie pożądany efekt, operator zdobędzie wiedzę o zachowaniu obiektu w okolicy aktualnego punktu pracy i będzie mógł wykorzystać tę wiedzę do dokładniejszej estymacji zachowania obiektu w okolicy aktualnego punktu pracy. Powyższa sytuacja odpowiada przełączeniu modułu optymalizacji z warstwy optymalizacji na modelu globalnym do warstwy optymalizacji stochastycznej, wykonaniu jednego lub więcej cykli testowych w warstwie optymalizacji stochastycznej, a następnie przejściu do warstwy optymalizacji na modelu mieszanym.

Porównując operatora procesu do systemu SILO należy pamiętać, że czynnik ludzki jest niezastąpiony w stanach nietypowej pracy obiektu (np.: w stanach awaryjnych). System SILO wdrażany jest w taki sposób, że decyzja o jego włączeniu lub wyłączeniu podejmowana jest przez operatorów procesu. Ludzki mózg ma naturalną zdolność do syntezy i generalizacji wiedzy oraz do swobodnego operowania pojęciami nieostrymi, rozmytymi. W przypadku awarii obiektu doświadczenie operatora i pewna całościowa

wiedza o obiekcie może mieć istotny wpływ na szybką i skuteczną reakcję na wykrytą awarię. Z drugiej strony w typowych stanach pracy obiektu system SILO może uzyskać rezultaty lepsze od operatora ze względu na:

- Bardzo dużą pojemność pamięci (w porównaniu z ludzkim mózgiem), w której przechowywane są reakcje obiektu na zmiany sterowań;
- Większą częstotliwość zmian sterowania, a zatem większą ilość sytuacji stanowiących potencjalne kwanty wiedzy o procesie;
- Możliwość wyznaczenia dokładnego, wielowymiarowego modelu optymalizowanego procesu.

## 8.5 Stabilność i niezawodność

W przypadku systemu SILO przeprowadzenie formalnego dowodu zbieżności opisanego w niniejszym rozdziale algorytmu nie jest trywialne. Składają się na to następujące czynniki:

- algorytm optymalizacji oparty o trzy przełączane między sobą algorytmy optymalizacji;
- niedeterministyczny algorytm użyty w warstwie optymalizacji stochastycznej;
- heurystyka skracania okresu optymalizacji w warstwie optymalizacji na modelu w przypadku intensywnego wzrostu wartości wskaźnika jakości.

Należy jednak pamiętać, że w przypadku wdrożenia systemu SILO nie jest konieczna analiza stabilności tego rozwiązania. Wynika to z faktu, że system SILO jest wdrażany w warstwie nadrzędnej w stosunku do warstwy regulacji podstawowej. System SILO modyfikuje wartości zadane regulatorów warstwy regulacji bezpośredniej. Zakres tych modyfikacji, oraz maksymalna dopuszczalna modyfikacja sterowań w jednym kroku optymalizacji ustalana jest w taki sposób, aby odpowiedzi obiektu na tą modyfikację sygnału sterowania były zawsze stabilne. Tak więc system SILO wprowadza do warstwy regulacji bezpośredniej pewne modyfikacje sygnałów sterowania w taki sposób, że po ich wprowadzeniu podstawowy układ sterowania znajduje się w obszarze bezpiecznej pracy, dla którego został zaprojektowany. W rozdziale 4 na rysunku 4.6 przedstawiono przykład hipotetycznej zależności między zawartością tlenu

w spalinach i relatywnym obciążeniu bloku energetycznego. Widać, że układ regulacji podstawowej zmienia wartość zadaną na poziom tlenu w spalinach w zależności od wartości sygnału obciążenia bloku. System SILO wdrożony w warstwie regulacji nadrzędnej modyfikuje wartość zadaną regulatora tlenu. Zakres tych modyfikacji mieści się jednak w granicach obszaru bezpiecznej pracy regulatora warstwy podstawowej. Tak więc przy założeniu, że:

- podstawowy układ regulacji zapewnia stabilną kontrolę nad procesem w pewnym bezpiecznym zakresie pracy;
- ograniczenia na wartość sterowań generowanych przez SILO są tak dobrane (po konsultacjach z kadrą inżynierską zakładu przemysłowego), że w każdej chwili system SILO pozostaje w zakresie bezpiecznej pracy podstawowego układu regulacji;
- ograniczenia na zmiany sygnałów sterujących generowanych przez SILO w jednym kroku optymalizacji są tak dobrane (po konsultacjach z kadrą inżynierską zakładu przemysłowego), że odpowiedź procesu na zmiany sterowania jest stabilna;

stabilność pracy systemu SILO jest zachowana. Nawet przy braku spełnienia ostatnich dwóch warunków, podstawowy system regulacji posiada zabezpieczenia w postaci ograniczeń na wartość i prędkość zmian sygnałów sterowania, tak więc stabilność pracy systemu SILO w układzie regulacji wielowarstwowej będzie zapewniona przez warstwę regulacji bezpośredniej. Potwierdzeniem niezawodności systemu SILO jest ciągła praca prezentowanego rozwiązania na obiektach opisanych w rozdziale 11 i w dodatku B.

# Rozdział 9 Porównanie właściwości systemu SILO i regulacji predykcyjnej

W rozdziale tym przeprowadzono teoretyczne porównanie właściwości systemu SILO i regulacji predykcyjnej MPC. Praktyczne porównanie jakości regulacji obu systemów zostało przeprowadzone w jednej z amerykańskich elektrowni na kotle energetycznym osiągającym moc 600 MW w pewnym ograniczonym zakresie obciążenia bloku. Wyniki tego porównania znajdują się w rozdziale 11, w którym zostało opisane wdrożenie systemu SILO w tej elektrowni na bloku 1. Problem z rzeczywistym porównaniem wydajności obu rozwiązań polega na niemożności instalacji systemu SILO i regulatora MPC na tym samym obiekcie przemysłowym. Główną przeszkodą jest tu wysoki koszt związany z wdrożeniem regulatora MPC. Kolejnym utrudnieniem jest konieczność wyrażenia zgody przez zakład przemysłowy na instalacje obu systemów regulacji, w szczególności na możliwość przeprowadzenia testów parametrycznych obiektu, w sytuacji posiadania rozwiązania nie wymagającego przeprowadzenia tej procedury. Tak więc ze względu na wymienione wyżej trudności, przybliżone porównanie rzeczywistej efektywności obu systemów można będzie przeprowadzić dopiero po ustaleniu średniej wydajności systemu SILO obliczonej na podstawie analizy wyników z kilkunastu lub kilkudziesięciu wdrożeń. Na obecnym etapie życia systemu SILO, pomimo bardzo dobrych wyników uzyskiwanych przez to rozwiązanie, próba wnioskowania o średniej efektywności systemu SILO byłaby niereprezentatywna.

## 9.1 Wdrożenie systemu optymalizacji

Firma wdrażająca regulator MPC do optymalizacji procesu technologicznego musi uwzględnić następujące fazy procesu implementacji regulatora (w nawiasach klamrowych podano czas trwania każdej fazy w przypadku implementacji regulatora MPC do optymalizacji procesu spalania w kotle energetycznym):

- Faza 1 [ok. 5 dni] – zdefiniowanie zadania optymalizacji;
- Faza 2 (opcjonalna) [ok. 10 dni] – przystosowanie systemu DCS do współpracy z nowym regulatorem;
- Faza 3 [ok. 1 dzień] – instalacja programu realizującego regulację nadrzędną;
- Faza 4 [ok. 21 dni] – testy parametryczne obiektu regulacji;
- Faza 5 [ok. 7 dni] – konstrukcja modelu procesu na podstawie danych z przeprowadzonych testów;
- Faza 6 [ok. 10 dni] – przetworzenie punktów procesowych, tak aby możliwa była optymalizacja tego procesu i konfiguracja parametrów regulatora;
- Faza 7 [ok. 3 dni] – testy odbiorcze;
- Faza 8 (opcjonalna) [ok. 14 dni] – ponowna identyfikacja modeli po założonym okresie czasu lub na życzenie klienta.

W fazie pierwszej definiowane jest zadanie regulacji. Inżynier wdrażający regulator musi wraz z przedstawicielami zakładu przemysłowego ustalić:

- cele optymalizacji (np: zwiększenie sprawności procesu);
- ograniczenia (np: ograniczenia na prędkości i zakres zmian sygnałów sterowania);
- dostępną moc obliczeniową przeznaczoną dla regulatora MPC.

W oparciu o te informacje inżynier wdrażający regulator ma za zadanie:

- zdefiniować minimalizowany wskaźnik jakości;
- zdefiniować zestaw sygnałów sterujących, za pomocą których regulator MPC będzie kontrolował proces. Związane jest to z ustaleniem zestawu urządzeń wykonawczych, będących pod kontrolą regulatora MPC;
- jeżeli to konieczne dokonać transformacji sygnałów związanych z procesem, tak aby uprościć zadanie optymalizacji. Przykładem takich przekształceń jest np: estymacja niemierzalnych wartości, grupowanie urządzeń wykonawczych i traktowanie ich jako jedna wirtualna zmienna sterująca;
- zdefiniować ograniczenia zadania optymalizacji.

Celem fazy drugiej jest dostosowanie systemu DCS do współpracy z regulatorem. Odbywa się to przez modyfikacje podstawowego układu sterowania tak aby uwzględnił on sygnały generowane przez regulator warstwy nadrzędnej. Ponadto należy zaimplementować mechanizmy pozwalające na bezpieczne włączenie i wyłączenie regulatora (tzw. *logiki załączenia* - patrz rozdział 4). Ostatnią czynnością jest dodanie i modyfikacja istniejących grafik operatorskich, tak aby operatorzy mogli szybko uzyskać informacje dotyczące pracy regulatora warstwy nadrzędnej. Powyższe czynności mogą zostać wykonane przez firmę wdrażającą regulator lub opcjonalnie przez pracowników zakładu przemysłowego.

Podczas fazy trzeciej instalowana jest aplikacja realizująca regulację predykcyjną. Zadaniem inżyniera wdrażającego regulator jest także poprawne skonfigurowanie komunikacji między systemem DCS i aplikacją regulatora. Aplikacja regulatora jest zazwyczaj wykonywana na osobnym komputerze. W przypadku prostych regulatorów MPC można także użyć rozwiązań wbudowanych w najnowsze systemy DCS [82].

Faza czwarta polega na przeprowadzeniu eksperymentów polegających na podawaniu na wejścia obiektu skoków jednostkowych i rejestracji czasowej odpowiedzi wyjść procesu. Aby uzyskać wiarygodne dane eksperymentalne, opisane testy trzeba powtórzyć kilkakrotnie. Jeżeli proces jest istotnie nieliniowy każdą serię eksperymentów trzeba przeprowadzić w okolicy różnych punktów pracy. Należy pamiętać, że nie zawsze istnieje możliwość wykonania testów obiektu w założonych punktach pracy obiektu regulacji. Ponadto zarząd zakładu przemysłowego może narzucić warunki na przeprowadzane testy i ograniczyć ich zakres. Skutkuje to oczywiście gorszym zestawem danych do identyfikacji modelu obiektu.

W fazie piątej, na podstawie uzyskanych danych eksperymentalnych, buduje się model obiektu. W przypadku obiektów istotnie nieliniowych najczęściej stosuje się quasi-liniowy model rozmyty. Pociąga to za sobą konieczność identyfikacji modelu w każdej z partycji rozmytych oraz konieczność zdefiniowania systemu rozmytego. Koszt budowy takiego modelu zależy od wymiaru wektora  $x$ ,  $y$  oraz  $z$  (9.1):

$$k = c \cdot n_{wej} \cdot n_{wyj} \quad (9.1)$$

gdzie:  $k$  – koszt modelu procesu,  $c$  – cena zamodelowania pojedynczej zależności między wejściem i wyjściem,  $n_{wej}$  – ilość wejść sterowanych i niesterowanych,  $n_{wyj}$  – ilość optymalizowanych wyjść.

Według ekspertów z firmy Honeywell [27] cena budowy dynamicznego modelu reprezentującego zależność między jednym wyjściem i jednym wejściem wynosi od



250 USD do 1000 USD. Koszt ten nie uwzględnia ceny oprogramowania i sprzętu oraz start finansowych poniesionych przez zakład przemysłowy w trakcie trwania testów, wynikających z nieefektywnego prowadzenia procesu.

W fazie szóstej tworzy się algorytmy modyfikujące sygnały reprezentujące punkty procesowe w taki sposób, aby możliwe było obsłużenie tego procesu przez regulator. Polega to na grupowaniu urządzeń wykonawczych w grupy wirtualnych zmiennych sterujących, definiowaniu niestandardowych ograniczeń wejściowych i wyjściowych specyficznych dla danego obiektu regulacji, filtrowaniu mocno zaszumianych sygnałów i obsługi sytuacji nietypowych takich jak np: kalibracja sygnałów pomiarowych. Ponadto inżynier wdrażający regulator dobiera zestaw parametrów konfiguracyjnych, specyficzny dla wybranej realizacji regulatora predykcyjnego. Faza siódma polega na przeprowadzeniu wraz z klientem kilkudniowych testów odbiorczych wdrożonego regulatora predykcyjnego. W przypadku systemu SILO test odbiorczy wykonywany jest po pewnym czasie od zakończenia wdrożenia (najczęściej ok. miesiąca).

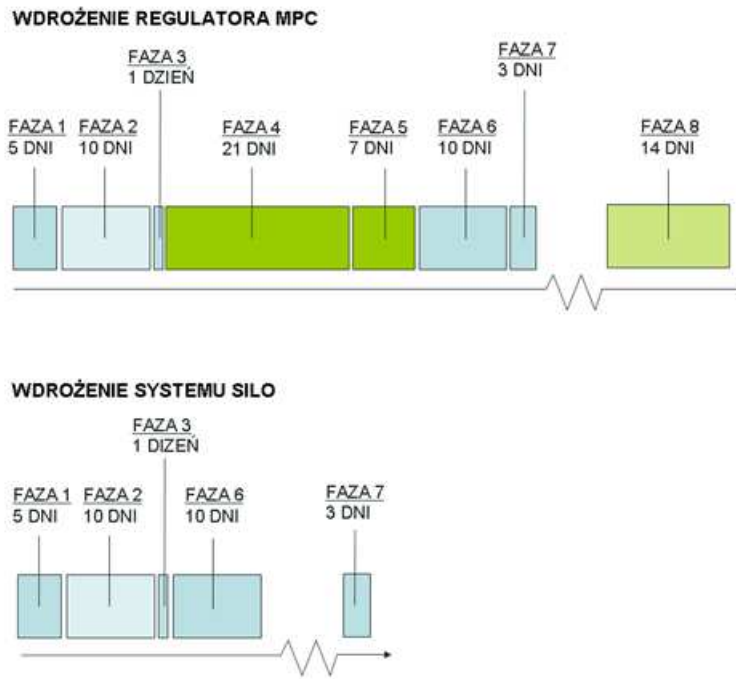
Może się również zdarzyć, że po pewnym okresie czasu następuje konieczność wykonania przez firmę wdrażającą regulator ponownej identyfikacji modelu obiektu. Pociąga to za sobą konieczność ponownego przeprowadzenia testów obiektu. Z doświadczenia firmy Transition Technologies S.A. wynika, że pomimo zastosowania długoterminowego algorytmu adaptacji, ponowna identyfikacja modelu wymagana jest średnio po ok. dwóch latach od momentu wdrożenia. Faza 8 trwa najczęściej krócej niż łączny czas wykoania fazy czwartej i piątej. Związane jest to z faktem, że inżynier wdrażający posiada już pewną wiedzę o danym obiekcie. Ponadto często nie jest potrzebne wykonywanie wszystkich eksperymentów.

Niektóre z powyższych faz są niezależne od przyjętego rozwiązania wdrażanego w warstwie nadrzędnej w stosunku do podstawowego układu regulacji. Fazy 1, 2, 3, 6 i 7 trzeba przeprowadzić zawsze, niezależnie od tego czy instalowany jest system SILO czy regulator predykcyjny. Fazy 4 i 5 są typowe dla regulacji predykcyjnej i innych rozwiązań bazujących na znanym *a priori* modelu obiektu regulacji. Faza 8 związana jest ze słabą efektywnością metody adaptacji lub brakiem takiej metody. W przypadku wszystkich wdrożeń systemu SILO nie wystąpiła konieczność ponownego strojenia parametrów modelu. Jedyne modyfikacje dotyczyły zmiany ograniczeń zmiennych sterujących i wag wskaźnika jakości. Związane one były ze zmianą założeń dotyczących bezpieczeństwa prowadzenia procesu i modyfikacją celów optymalizacji.

Zmiany te zostały przeprowadzone przez pracowników elektrowni i nie potrzebna była interwencja inżyniera wdrażającego SILO.

Na rys. 9.1 przedstawiono schematycznie kolejne fazy wdrożenia regulatora MPC i systemu SILO. Pomimo, że długości poszczególnych faz zostały wyznaczone jedynie szacunkowo, widać wyraźną oszczędność czasu podczas wdrożenia SILO związaną z brakiem fazy wykonywania testów identyfikacyjnych i budowy modelu obiektu przez inżynierów wdrażających system. W systemie SILO odpowiednikiem testów identyfikacyjnych jest heurystyka zaimplementowana w warstwie optymalizacji stochastycznej (patrz rozdział 8). Ponadto dzięki temu, że metoda adaptacji zaimplementowana w SILO spełnia pokładane w niej nadzieje, nie ma potrzeby wykonywania fazy ósmej. Oszczędność czasu w sposób bezpośredni przekłada się na niższy koszt wdrożenia systemu SILO w porównaniu do rozwiązań opartych na regulacji predykcijnej. Widać więc, że w przypadku optymalizacji procesów technologicznych, w których zakłócenia zmieniają się rzadko i szybko, lub w sposób ciągły, ale wolno w kontekście dynamiki obiektu, system SILO stanowi tanią alternatywę dla metod realizujących regulację predykcijną, co stanowi potwierdzenie tezy roboczej 1.2.3 (patrz rozdział 1).

Analizując wdrożenie regulatora MPC i SILO należy pamiętać, że po zakończonej implementacji regulacji predykcijnej firma wykonująca wdrożenie powinna przeprowadzić testy odbiorcze. Po udanym wdrożeniu, dla zidentyfikowanych punktów pracy obiektu, regulacja predykcijna spełnia stawiane przed nią oczekiwania. Nieznane jest natomiast zachowanie regulatora w przyszłości. Na horyzoncie czasowym liczącym w miesiącach charakterystyki obiektu mogą ulec takim zmianom, że model obiektu będzie zbyt niedokładny aby umożliwić zapewnienie dobrej jakości regulacji. W przypadku systemu SILO sytuacja jest zgoła odmienna. Po zakończeniu fazy szóstej system SILO dopiero zaczyna zdobywać wiedzę o obiekcie. W przypadku optymalizacji procesu spalania w kotle energetycznym, w ciągu pierwszych 24 godzin pracy, dominują pierwotne odpowiedzi immunologiczne - system pracuje w warstwie optymalizacji stochastycznej. Na podstawie automatycznie wykonywanych testów identyfikacyjnych moduł uczący tworzy nowe kwanty wiedzy o obiekcie. W ciągu kolejnych dni system SILO wykorzystuje nowo nauczone limfocyty do budowy modeli mieszanych (warstwa optymalizacji na modelu mieszanym). W przypadku pojawienia się nowych wartości zakłóceń system SILO używa modelu globalnego. Jeżeli jakość modelu globalnego i mieszanego będzie niewystarczająca wówczas następuje przejście do warstwy optymalizacji stochastycznej. Po ok. dwóch tygodniach od momentu zakończenia fazy szóstej



Rysunek 9.1 Fazy wdrożenia regulatora MPC i systemu SILO.

system SILO potrafi efektywnie realizować cele optymalizacji w typowych konfiguracjach pracy kotła energetycznego. Test odbiorczy jest więc wykonywany zazwyczaj po ok. miesiącu od zakończenia wdrażania regulatora. Widać więc, że w przypadku systemu SILO, po zakończeniu fazy szóstej, inżynier wdrażający nie ma komfortu psychicznego polegającego na przekonaniu, że wdrożone rozwiązanie spełnia wymóg jakości regulacji. Na weryfikację tej hipotezy należy poczekać kilka dni, podczas których SILO będzie uczył się procesu. Ponadto w przypadku wdrożenia regulatora MPC w razie nie spełnienia wymogów dotyczących celów optymalizacji można od razu przystąpić do weryfikacji fazy pierwszej, czwartej i piątej. Zmiana struktury zadania optymalizacji, a więc zmiana zestawu używanych sygnałów związanych z punktami procesowymi pociąga jednak za sobą konieczność wykonania dodatkowych testów i przebudowania modeli dynamicznych. Tak więc oszczędność czasu wynikająca z możliwości oceny jakości regulacji zaraz po zakończeniu fazy szóstej jest zużywana na dokonanie dodatkowych testów i ponowne przeuczanie modeli. W odróżnieniu od wdrożenia regulatora MPC, firma implementująca system SILO, po wykonaniu fazy siódmej ma większe zaufanie odnośnie zachowania się optymalizatora w przyszłości.

Brak pewności co do wymaganej efektywności systemu SILO na samym początku istnienia tego rozwiązania (zanim nastąpiły pierwsze wdrożenia) sprawił, że optymalizator SILO oferowany było jak narzędzie do przeprowadzania automatycznych testów obiektu. Dane z tych testów mogły być użyte do budowy modeli dynamicznych wykorzystywanych w regulacji predykcyjnej. Tak więc pierwsze wdrożenia systemu SILO miały na celu realizację poniższych zadań:

- zadanie główne – wykonywanie, na potrzeby implementacji regulatora MPC, automatycznych testów obiektu z wykorzystaniem warstwy optymalizacji stochastycznej;
- zadanie opcjonalne – bieżąca optymalizacja punktu pracy procesu technologicznego bez użycia regulatora predykcyjnego w przypadku stwierdzenia, że przy użyciu systemu SILO można zrealizować narzucone cele optymalizacji.

W podejściu tym wykorzystano fakt, że pierwsze trzy fazy pokazane na rys. 9.1 są prawie identyczne dla systemu SILO i regulatora MPC. Takie podejście pozwala na oszczędność czasu pracy związanego z fazą czwartą w przypadku implementacji regulatora MPC i zmniejszenie ryzyka związanego z nieefektywną pracą system SILO. Dane związane z rejestracją odpowiedzi skokowych obiektu uzyskane w wyniku pracy systemu SILO w warstwie optymalizacji stochastycznej nigdy nie zostały jednak wykorzystane do budowy modelu na potrzeby regulatora MPC, ponieważ w przypadku każdego z wdrożeń systemu SILO jakość regulacji była wystarczająco wysoka. Obecnie, po udanych wdrożeniach systemu SILO (patrz dodatek B) nie rozpatruje się użycia systemu SILO jako narzędzia realizującego automatyczne testy obiektu regulacji na potrzeby wdrożenia regulatora MPC.

## 9.2 Porównanie postaci modelu i wskaźnika jakości, oraz innych właściwości obu rozwiązań

Podstawowa różnica między modelem wykorzystywanym przez system SILO i regulator MPC jest taka, że regulator MPC korzysta z dynamicznego modelu zbudowanego w oparciu o testy obiektu przeprowadzane przez człowieka, a system SILO korzysta ze statycznego modelu przyrostowego tworzonego w każdym kroku optymalizacji na podstawie automatycznych testów obiektu. Widać więc, że regulator MPC będzie charakteryzował się lepszą jakością regulacji w tzw. stanach przejściowych.

Szacowana jakość regulacji w stanach ustalonych jest porównywalna dla obu systemów. Przy założeniu, że:

- jakość regulacji i bezpieczeństwo procesu w stanach przejściowych zapewnione jest głównie przez warstwę regulacji bezpośredniej;
- przez większość czasu główne zakłócenia oddziałujące na proces znajdują się na w przybliżeniu stałym poziomie - dominuje regulacja w stanie ustalonym;

potencjalne oszczędności regulacji predykcyjnej związane z efektywniejszym prowadzeniem procesu w stanach przejściowych nie zawsze rekompensują koszty związane z pracą wykonaną przez wysoko wykwalifikowanych inżynierów realizujących zadanie testowania obiektu i budowy modelu dynamicznego.

Regulator MPC jest wrażliwy na niedokładności modelowania. W sytuacji niedokładnego modelu precyzyjne prawo sterownia obliczone w oparciu o model może nie zapewniać dobrej jakości regulacji. System SILO potrafi wykryć, że dalsza minimalizacja wskaźnika jakości w oparciu o używany model nie jest możliwa. Wówczas system SILO *traci* zaufanie do modelu i stara się znaleźć lepszy wektor sterowań w oparciu o heurystykę warstwy regulacji stochastycznej. W warstwie tej system SILO stara się nie tylko zmniejszyć wartość wskaźnika jakości, ale również poprawić jakość modelu poprzez dokładną naukę optymalizowanego procesu w okolicy aktualnego punktu pracy. Znalezione w tej warstwie rozwiązanie stanowi punkt startowy dla zadania optymalizacji wykonywanego w oparciu o zaktualizowany model procesu.

Analizując wykorzystanie modelu w systemie SILO widać pewną analogię do quasi-liniowych modeli rozmytych używanych w regulacji predykcyjnej. W obu podejściach wykorzystuje się kawałkami liniową aproksymację charakterystyki obiektu regulacji. W quasi-liniowym modelu rozmytym *a priori* definiuje się przedziały (partycje rozmyte), w których liniowa aproksymacja jest uzasadniona. W systemie SILO automatycznie wykonywana jest liniowa aproksymacja optymalizowanego procesu w każdym kroku optymalizacji w okolicy aktualnego punktu pracy, w oparciu o najbardziej aktualne dane zmierzone w okolicy aktualnego punktu pracy. Takie podejście sprawia, że w przypadku SILO możliwe jest wymuszenie większej dokładności modelowania charakterystyki statycznej, poprzez ustalenie większej liczby sygnałów i węższych przedziałów zmienności wartości tych sygnałów, które definiują obszar pracy, w którym aproksymacja procesu modelem liniowym jest wystarczająco dokładna. W przypadku regulatorów MPC ilość takich obszarów była ograniczona przez nakład

pracy związany z wykonaniem testów parametrycznych obiektu w każdym z tych obszarów.

Standardowa postać wskaźnika jakości używana w regulatorach MPC uwzględnia karę na zmiany sterowania. Dzięki temu można odpowiednio dobrać stopień *agresywności* regulatora MPC. W SILO nie ma potrzeby wprowadzania kary za zbyt dużą zmienność trajektorii sterowań. Wynika to z tego, że w zdecydowanej większości przypadków sterowania są zmieniane nie częściej niż czas potrzebny na ustalenie się wyjść obiektu. Ponadto podczas pracy w warstwie optymalizacji stochastycznej jak i w jednej z dwóch warstw optymalizacji wykorzystujących model, maksymalny przyrost sterowania jest tak dobrany, aby nie powodować opuszczenia bezpiecznego obszaru pracy warstwy regulacji podstawowej.

Obecnie istnieją dowody stabilności dla większości popularnych algorytmów regulacji predykcyjnej. Nie zmienia to faktu, że w początkowych latach istnienia regulacji predykcyjnej nie było takich dowodów stabilności [99], a mimo to regulatory te (głównie DMC) były z powodzeniem wdrażane do sterowania procesami przemysłowymi [22, 84]. W przypadku systemu SILO nie przeprowadzono formalnego dowodu stabilności, ze względu na istotne trudności omówione w rozdziale 8. Potwierdzeniem niezawodności systemu SILO jest ciągła praca prezentowanego rozwiązania na obiektach opisanych w rozdziale 11 i w dodatku B.

Regulatory MPC są od wielu lat stosowane w różnych gałęziach przemysłu [86]. W tym czasie zdążyły potwierdzić swoją praktyczną użyteczność i zdobyć zaufanie klientów przemysłowych. W odróżnieniu od systemu SILO algorytmy regulacji predykcyjnej zostały dokładnie przetestowane w wielu zakładach przemysłowych na całym świecie. System SILO został wdrożony dopiero na dziewięciu blokach energetycznych (patrz dodatek B). Wraz z kolejnymi udanymi wdrożeniami zaufanie klientów przemysłowych do systemu opartego na teorii Sztucznych Systemów Immunologicznych powinno rosnać.

Istotną dla kadry operatorskiej cechą regulacji predykcyjnej jest jej deterministyczny charakter. Stochastyczny algorytm zaimplementowany w SILO powoduje, że zachowanie systemu jest nieraz trudne do przewidzenia. Tak więc kadra operatorska kontrolująca proces czuje większy komfort psychiczny w przypadku, gdy w warstwie regulacji nadrzędnej zaimplementowany jest regulator predykcyjny.

Z drugiej jednak strony bardzo istotną dla kadry zarządzającej cechą systemu SILO jest jego niski koszt, w porównaniu do rozwiązań opartych na regulacji predykcyjnej. Ponadto brak testów identyfikacyjnych, przeprowadzanych przez kadrę inżynierską według założonego planu testów, oznacza brak konieczności zmiany harmonogramu produkcji (problem zapewnienia odpowiedniego punktu pracy podczas testów) i brak nieefektywnego prowadzenie procesu w czasie eksperymentów identyfikacyjnych.

# Rozdział 10 Proces spalania w kotle energetycznym

Przedstawiony w niniejszej rozprawie system SILO został stworzony z myślą o bieżącej optymalizacji punktu pracy procesów technologicznych, w szczególności procesu spalania zachodzącym w kotle energetycznym dużej mocy. Kotły takie instalowane są w elektrowniach kondensacyjnych i elektrociepłowniach. W elektrowni parowej klasycznej (nazywanej również konwencjonalną) wytworzona w procesie spalania paliwa organicznego energia cieplna jest przekazywana wytworzonej w kotle parze wodnej. Para ta wykonuje pracę w turbinie parowej, w wyniku czego w prądniczy energia mechaniczna zamieniana jest na energię elektryczną. Więcej na temat przemian energetycznych zachodzących w elektrowniach cieplnych znaleźć można w [60, 32, 88].


System SILO służy do bieżącej optymalizacji procesów, w których główne zakłócenia oddziałujące na proces utrzymują się na mniej więcej stałym poziomie (z dokładnością do szumów i oscylacji sygnałów) przez dłuższy okres czasu. Z tego względu SILO nie spełni pokładanych w nim nadziei w elektrowniach szczytowych. SILO może być stosowane w elektrowniach podstawowych, oraz w elektrowniach podszczytowych [60].

## 10.1 Proces technologiczny elektrowni

Cztery najważniejsze układy procesu technologicznego elektrowni to:

- układ paliwo-powietrze-spaliny;
- układ cieplny (układ parowo-wodny);
- układ chłodzenia skraplaczy;
- układ wyprowadzenia mocy (układ elektryczny).





Rysunek 10.1 Schemat procesu technologicznego elektrowni parowej, ograniczony do układu paliwo-powietrze-spaliny i części układu cieplnego: 1 - podajniki węgla; 2 - młyny węglowe; 3 - klapy powietrza wtórnego; 4 - klapy OFA (ang. Over Fire Air); 5 - skrzynia rozdzielcza powietrza wtórnego; 6 - palniki (doprowadzenie paliwa); 7 - wentylator młynowy; 8 - wentylator powietrza; 9 - podgrzewacz powietrza; 10 - elektrofiltr; 11 - wentylator spalin; 12 - komin; 13 - walczak; 14 - parownik; 15 - komora paleniskowa; 16 - układ przegrzewaczy pary wtórnej; 17 - schładzacz wtryskowy; 18 - układ przegrzewaczy pary świeżej.

Z punktu widzenia optymalizacji procesu spalania w kotle energetycznym, najważniejsze dwa układy to układ paliwo-powietrze-spaliny i układ cieplny. Przedstawione układy zostaną omówione na przykładzie kotła pyłowego z palnikami pyłowymi i walczakiem.

W układzie *paliwo-powietrze-spaliny* (patrz rys. 10.1) do komory paleniskowej 15 dostarczane jest paliwo i powietrze. W wyniku procesu spalania powstają gorące spaliny, które omywają powierzchnie ogrzewalne 14, 16 i 18, oraz oddają ciepło wodzie zasilającej w podgrzewaczu wody zasilającej. Paliwo do komory paleniskowej dostarczane jest poprzez palniki 6 w postaci mieszanki pyłowo-powietrznej. Mieszanka ta powstaje w młynach węglowych 2. Podajniki węgla 1 dostarczają do młynów węgiel, a wentylator młynowy 7 reguluje ilość dostarczanego do młynów powietrze pierwotnego. Aby możliwy był proces spalania, do komory paleniskowej dostarczane jest powietrze wtórne. Wentylator powietrza 8 dostarcza powietrze do skrzyni rozdzielczej powietrza wtórnego 5. Ciśnienie panujące w skrzyni jest wyższe niż ciśnienie w komorze paleniskowej. Powietrze dostaje się do komory paleniskowej poprzez kłapy powietrze wtórnego 3. Dodatkowo w skład instalacji kotłowej mogą wchodzić kłapy OFA 4, dostarczające powietrza do wyższej części komory. Zazwyczaj o ilości tlenu w komorze spalania decyduje wentylator powietrza. Różnica ciśnień między skrzynią rozdzielczą powietrza wtórnego i komorą paleniskową regulowana jest poprzez poziom otwarcia klap powietrza wtórnego. Należy pamiętać, że nie są to jedyne stosowane rozwiązania. Kształt płomienia w komorze paleniskowej przy danym obciążeniu bloku można kształtować poprzez zmianę poziomu tlenu w spalinach 8, regulację otwarcia klap powietrza wtórnego 3 i klap OFA 4, lub regulację prędkości poszczególnych podajników węgla 1 (pamiętając o tym, aby sumaryczna ilość paliwa dostarczanego do kotła wynikała z obciążenia bloku). Powstałe w komorze paleniskowej spaliny omywają powierzchnie ogrzewalne 14, 16, 18, oraz podgrzewają wodę zasilającą. Ciepło zawarte w spalinach służy również do podgrzania powietrza dostarczanego do komory paleniskowej. Wymiana ciepła następuje w podgrzewaczu powietrza 9. Następnie w elektrofiltrze 10 spaliny podlegają procesowi odpylenia. Wentylator spalin 11 wpływa na ciśnienie panujące w komorze spalania, wymuszając tym samym obieg spalin. Spaliny poprzez komin 12 wydostają się do atmosfery.


W układzie *cieplnym parowo-wodnym* w rurach składających się na parownik 6, przegrzewacze pary 16 i 18, oraz podgrzewacz wody zasilającej, krąży czynnik roboczy. Czynnik ten występuje w postaci wody, mieszaniny parowo-wodnej, pary nasyconej

suchej i pary przegrzanej. W walczaku 13 para oddzielana jest od wody. Osuszona, pozbawiona soli para jest następnie przegrzewana w przegrzewaczu pary świeżej 18. Pomędzy kolejnymi stopniami przegrzewacza znajdują się schładzacz wtryskowe 17. Ich zadaniem jest regulacja temperatury pary. Przegrzana para świeża dostarczana jest do części wysokoprężnej turbiny, gdzie następuje rozprężenie pary. Energia ciepła jest zamieniana w energię mechaniczną ruchu obrotowego turbiny. Rozprężona para jest ponownie przegrzewana w przegrzewaczu pary wtórnej. Pomędzy kolejnymi stopniami przegrzewacza również znajdują się schładzacz wtryskowe. Wtórnie przegrzana para dostarczana jest do kolejnych stopni turbiny, gdzie wykonuje pracę związaną z ruchem obrotowym turbiny. Po wykonaniu pracy w turbinie, para skraplana jest w skraplaczu, przy użyciu wody chłodzącej. Skropliny pompowane są do zbiornika wody zasilającej. Do zbiornika tego dostarczana jest też woda uzupełniająca, rekompensująca ewentualne straty wody w przedstawionym obiegu. Ze zbiornika wody zasilającej woda pompowana jest z powrotem do walczaka. Po drodze następuje podgrzanie wody zasilającej. Wykorzystuje się do tego ciepło zawarte w spalinach. Woda z walczaka podgrzewana jest w rurach tworzących układ parownika 6, znajdujących się w komorze paleniskowej 15. Do walczaka wraca mieszanina parowo-wodna.

Zadaniem *układu chłodzenia* jest wyprowadzenie z obiegu ciepła, które pozostało w parze po wykonaniu przez parę pracy w turbinie. Używa się do tego celu wody chłodzącej. Więcej na ten temat w [38].

W układzie *wyprowadzenia mocy* energia mechaniczna zamieniana jest w napędzaną przez turbinę prądnicy na energię elektryczną. Dwa ostatnie układy nie są na tyle istotne w kontekście optymalizacji procesu spalania, aby poświęcać im więcej miejsca. Więcej na ten temat w [60].

W wyniku spalania paliwa w kotle energetycznym powstają m.in. tlenek i dwutlenek węgla ( $\text{CO}$  i  $\text{CO}_2$ ), tlenki siarki ( $\text{SO}_x$ ) oraz tlenki azotu ( $\text{NO}_x$ ). Tlenki azotu po połączeniu z wodą tworzą kwasy azotowe, które są składnikiem kwaśnych deszczów. Tlenki azotu powodują również niszczenie warstwy ozonowej. Zwiększenie temperatury spalin w jądrze płomienia powoduje zwiększenie koncentracji tlenków azotu. Emisja  $\text{NO}_x$  zwiększa się również w wyniku wydłużenia się czasu przebywania cząstek w strefie wysokich temperatur [60], oraz w wyniku zwiększenia koncentracji tlenu. Należy jednak pamiętać, że zmniejszenie koncentracji tlenu prowadzi do wzrostu emisji tlenku węgla (patrz rys. 10.2).



Rysunek 10.2 Przykładowa zależność emisji CO i NO<sub>x</sub> w zależności od nadmiaru powietrza [37].

W związku z coraz bardziej restrykcyjnymi normami dotyczącymi emisji szkodliwych związków do atmosfery, zakłady energetyczne, a w szczególności elektrownie dużej mocy, dążą do zmniejszenia emisji tych związków. Analizując rysunek 10.2 wiadać, że próba obniżenia emisji NO<sub>x</sub> często wiąże się z podwyższeniem emisji tlenków węgla. Metody obniżenia emisji NO<sub>x</sub> dzielą się na metody pierwotne i metody wtórne. Metody pierwotne polegają na ograniczeniu ilości powietrza doprowadzanego do pasa palnikowego, oraz na doprowadzeniu powietrza uzupełniającego poprzez klapy OFA. Zastosowanie odpowiednich palników niskoemisyjnych, reorganizacja sposobu doprowadzania mieszanki pyłowo-powietrznej i powietrza wtórnego do komory paleniskowej może istotnie wpłynąć na redukcję emisji NO<sub>x</sub>. Metody wtórne polegają na usuwaniu tlenków azotu ze spalin powstałych w wyniku procesu spalania. Do najpopularniejszych metod tego typu zalicza się selektywną redukcję katalityczną (SCR - Selective Catalytic Reduction), oraz selektywną redukcję niekatalityczną (SNCR - Selective Non-Catalytic Reduction). Wdrożenie metod wtórnych i pierwotnych przynosi najczęściej spodziewane efekty, jednak wiąże się z bardzo dużym nakładem środków finansowych. Wynika to z konieczności przebudowy instalacji kotłowej, co wiąże się również z koniecznością odstawienia kotła na pewien okres czasu. Zmniejszenie emisji NO<sub>x</sub> można uzyskać również poprzez strojenie podstawowego układu regulacji i/lub

wdrożenie zaawansowanej regulacji procesu spalania (zdecydowanie przeważają metody regulacji predykcyjnej). Są to metody znacznie tańsze, zwykle jednak nie są one tak skuteczne jak metody związane z przebudową instalacji kotłowej.

Blok energetyczny jest obiektem regulacji posiadającym wiele wyjść i wiele wejść. Wejścia obiektu oddziałują na wyjścia w torach głównych i licznych torach skrośnych, co powoduje że poszczególne pętle regulacji oddziałują na siebie. Wyróżnia się następujące układy automatycznej regulacji procesów cieplnych [60]:

- Układ automatycznej regulacji mocy. W układzie tym regulator kontroluje stopień otwarcia zaworów regulacyjnych turbiny;
- Układ automatycznej regulacji ciśnienia pary. W układzie tym regulator oddziałuje na obciążenie podajników węgla 1, kontrolując w ten sposób strumień paliwa dostarczanego do kotła;
- Układ automatycznej regulacji temperatury pary pierwotnej i wtórnej. W układzie tym stosuje się kaskadowe układy regulacji [82]. Ich zadaniem jest utrzymanie odpowiedniej temperatury pary świeżej i wtórnej. Do tego celu używa się schładzaczy pary 17;
- Układ automatycznej regulacji zasilania kotła wodą. Zadaniem tego układu jest kontrola dopływu strumienia wody do kotła, w taki sposób aby równoważyć strumień pary pobieranej z kotła. Zwykle układ ten oddziałuje na obciążenie pompy wody zasilającej lub na zawór regulacyjny wody zasilającej;
- Układ automatycznej regulacji procesu spalania. Układ ten oddziałuje zazwyczaj na obciążenie wentylatorów powietrza 8. Jego zadaniem jest utrzymanie zadanej wartości nadmiaru powietrza w komorze paleniskowej;
- Układ automatycznej regulacji podciśnienia w komorze paleniskowej. Układ ten oddziałuje na obciążenie wentylatorów spalin 11. Jego zadaniem jest utrzymanie stałego podciśnienia w komorze paleniskowej.


Pętle regulacji oparte są głównie na regulatorach PID. Wykorzystywane są również pewne modyfikacje tych regulatorów takie jak regulacja PID z korekcją od sygnału zakłócenia (sterowanie typu feedforward) [77, 45] oraz regulacja PID ze zmiennym wzmocnieniem (tzw. gain scheduling) [123]. Bardzo często sterowania generowane w

przedstawionych podstawowych układach automatycznej regulacji stanowią wartości zadane dla innych układów regulacji, związanych z poszczególnymi urządzeniami. Powoduje to powstawanie tzw. kaskad regulatorów PID. Duża liczba wzajemnie na siebie oddziałujących układów regulacji sprawia, że dobre zestrojenie tych układów, uwzględniające często sprzeczne ze sobą cele optymalizacji, jest rzeczą bardzo trudną. Ponadto charakterystyki pracy kotła są niestacjonarne, co pociąga za sobą konieczność ciągłego strojenia tych układów. Dlatego w celu optymalizacji procesu spalania stosuje się często metody *zaawansowanej regulacji*. Do najpopularniejszych metod tego typu zaliczyć można regulację predykcijną z przesuwającym horyzontem. Przedstawiony w niniejszej pracy system SILO stanowi alternatywne podejście do problemu optymalizacji procesu spalania.

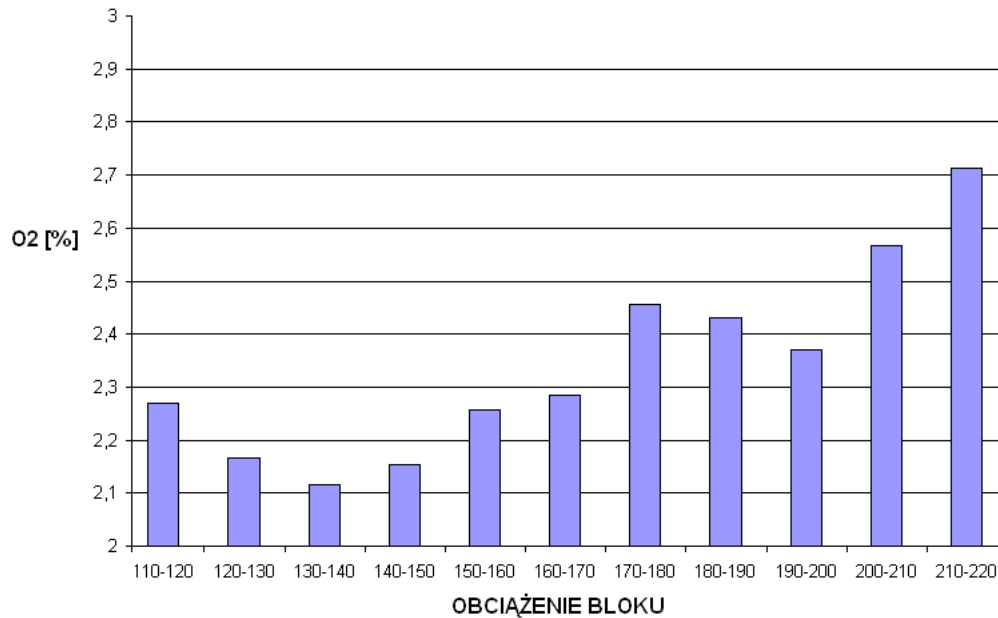
## 10.2 Kocioł energetyczny jako obiekt regulacji

Z punktu widzenia systemu SILO oraz metod regulacji predykcyjnej, kocioł energetyczny to obiekt typu MIMO (ang. Multi Input Multi Output) posiadający niemożliwe do pominięcia skrośne zależności między wyjściami i wejściami obiektu. Proces spalania zachodzący w kotle to nieliniowy, dynamiczny proces, charakteryzujący się stosunkowo długimi odpowiedziami na zmianę sterowania (czas odpowiedzi sygnałów emisji CO i NO<sub>x</sub> wynosi od kilku do kilkunastu minut). Na proces ten oddziałują zakłócenia. Głównym zakłóceniem z punktu widzenia optymalizacji tego procesu jest obciążenie bloku, oraz konfiguracja pracujących młynów węglowych (patrz rys. 10.3, 10.4, 10.5 i 10.6). Na proces oddziałują też niemierzalne lub rzadko mierzone zakłócenia takie jak jakość przemiału w młynach węglowych, czy wilgotność węgla. Charakterystyki procesu spalania zmieniają się wraz z upływem czasu. Zmiany te, rozpatrywane na horyzoncie miesięcy i lat, wynikają ze zużycia i awarii urządzeń kotłowych, zmiany sposobu prowadzenia kotła, przebudowy powierzchni ogrzewalnych, istotnych zmian charakterystyk używanego paliwa (np: decyzja o używaniu domieszki biomasy), zmiany warunków zewnętrznych (uwzględnienie sezonowości), zmiany jakości mielenia w młynach węglowych itp.


Na rysunku 10.7 przedstawiono kocioł energetyczny, jako obiekt zaawansowanej regulacji. Typowe cele optymalizacji procesu spalania to: obniżenie emisji NO<sub>x</sub> i CO, zwiększenie efektywności kotła, utrzymanie temperatur pary świeżej i wtórnej oraz




Rysunek 10.3 Poziom emisji NO<sub>x</sub> w zależności od obciążenia bloku. Wykres stworzony na podstawie danych zebranych w jednej z polskich elektrowni w okresie od 1 do 31 lipca 2006 r.



Rysunek 10.4 Zawartość tlenu w spalinach w zależności od obciążenia bloku. Wykres stworzony na podstawie danych zebranych w jednej z polskich elektrowni w okresie od 1 do 31 lipca 2006 r.



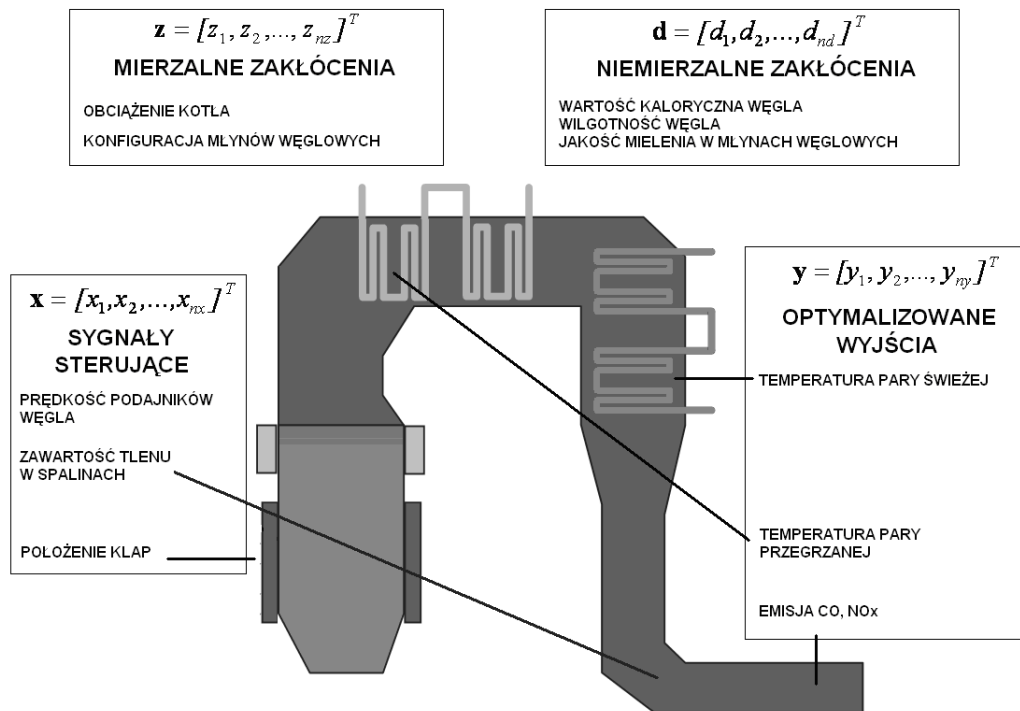
Rysunek 10.5 Poziom emisji NO<sub>x</sub> w zależności od konfiguracji pracy młynów węglowych. Wykres stworzony na podstawie danych zebranych w jednej z polskich elektrowni w okresie od 1 do 31 lipca 2006 r.



Rysunek 10.6 Zawartość tlenu w spalinach w zależności od konfiguracji pracy młynów węglowych. Wykres stworzony na podstawie danych zebranych w jednej z polskich elektrowni w okresie od 1 do 31 lipca 2006 r.



temperatury wylotowej spalin na odpowiednim poziomie, minimalizacja różnicy poziomu tlenu po obu stronach kotła. Cele te są często sprzeczne ze sobą (patrz rys. 10.2). Ponadto istnieją ograniczenia zadania optymalizacji na: minimalną i maksymalną wartość sygnałów sterujących (np.: wartość poziomu tlenu w spalinach nie może znajdować się poza zakresem od 2 do 6 %), przyrost sygnałów sterowania w jednym kroku optymalizacji (np.: bezwzględny przyrost poziomu tlenu w spalinach nie może przekroczyć 0.15 % w jednym kroku optymalizacji), oraz na wartości wyjść procesu (np.: emisja CO nie może przekroczyć poziomu 250 mg/Nm<sup>3</sup>). Ograniczenia te mogą zmieniać się w raz ze zmianą punktu pracy procesu spalania.



Rysunek 10.7 Schematyczne przedstawienie przykładowych sygnałów wejściowych i wyjściowych kotła energetycznego, istotnych z punktu widzenia optymalizacji procesu spalania.

Rozpatrując zadanie wdrożenia zaawansowanego regulatora procesu spalania należy pamiętać o wielu inżynierskich problemach takich jak: zaszumienie sygnałów pomiarowych, awarie urządzeń wykonawczych oraz oscylacje sygnałów wynikające z niedostatecznego zestrojenia układów automatycznej regulacji. Uwzględnienie nieliniowości procesu spalania w regulatorach MPC, polega najczęściej na zastosowaniu

podjęcia Takagi-Sugeno. Rozmycie modeli dokonywane jest zazwyczaj w oparciu o sygnał obciążenia bloku energetycznego. W elektrowniach opalanych węglem, innymi istotnymi sygnałami definiującymi obszary pracy, w których liniowa aproksymacja charakterystyki procesu jest wystarczająco dokładna, jest konfiguracja pracujących młynów węglowych i poziom emisji CO. Informacje te nie są jednak najczęściej używane podczas definiowania partycji rozmytych, ze względu na wysoki koszt stworzenia modelu obiektu. W systemie SILO pomiar emisji CO jak również pomiar prędkości poszczególnych podajników węgla jest brany pod uwagę przy wyznaczaniu siły wiązania antygen-przeciwciała. Informacja o sile wiązania wykorzystywana jest do selekcji limfocytów reprezentujących aktualny punkt pracy.

# Rozdział 11 Wyniki i analiza wdrożeń systemu SILO

System SILO został wdrożony na czterech blokach energetycznych w Polsce, oraz na pięciu blokach energetycznych w USA. Wdrożenia były przeprowadzane we współpracy z firmą Transition Technologies S.A. i Emerson Process Management.


## 11.1 Wdrożenie systemu SILO w jednej z amerykańskich elektrowni

Rozpatrywana elektrownia składa się z dwóch bloków energetycznych. Zarówno blok pierwszy jak i drugi mogą pracować przy maksymalnym obciążeniu 615 MW. Na rysunku 11.1 znajduje się schemat przedstawiający budowę kotłów energetycznych pracujących na bloku pierwszym i drugim.

Na obydwu blokach jako paliwa używa się węgla kamiennego. Mieszanka paliwowo-powietrzna jest dostarczana do komory spalania za pomocą palników umieszczonych na sześciu poziomach w każdym z czterech rogów komory spalania. Cztery palniki umieszczone na tym samym poziomie w każdym z rogów komory spalania połączone są z jednym młynem węglowym. Oprócz klap powietrza wtórnego w kotle zainstalowano również dwa poziomy klap CCOFA (ang. Close Coupled Over Fire Air), oraz klapy SOFA (ang. Separated Over Fire Air - patrz rys. 11.2). Na bloku pierwszym występują trzy poziomy klap SOFA, a na bloku drugim znajduje się sześć poziomów klap SOFA.

Na obu blokach zainstalowany jest system Ovation 3.0 oparty na platformie Windows XP. Jest to system DCS firmy Emerson Process Management. System SILO był wdrażany na osobnym komputerze z zainstalowanym systemem Red Hat Linux 4. Komputer ten był podłączony do sieci intranetowej.

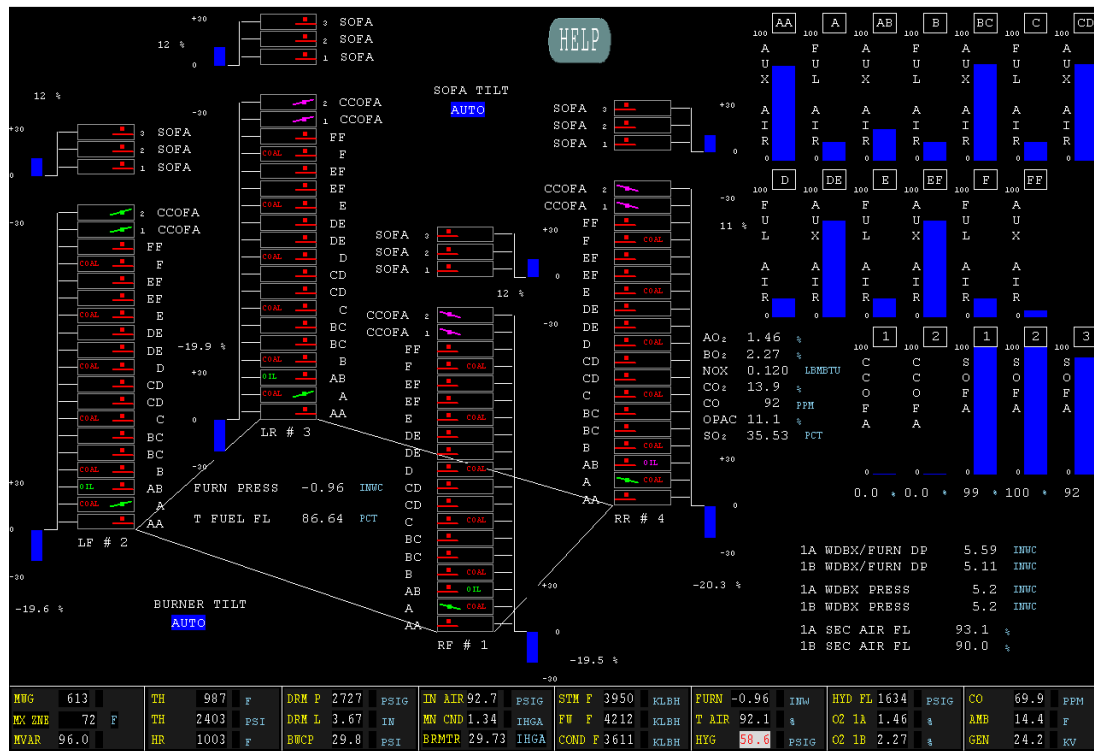
Celem wdrożenia systemu SILO w tej elektrowni była minimalizacja emisji  $\text{NO}_x$  przy jednoczesnym utrzymaniu poziomu chwilowej emisji CO poniżej 400 PPM (ang.



**POWER STATION - UNIT 1  
C-E CONTROLLED CIRCULATION STEAM GENERATOR**

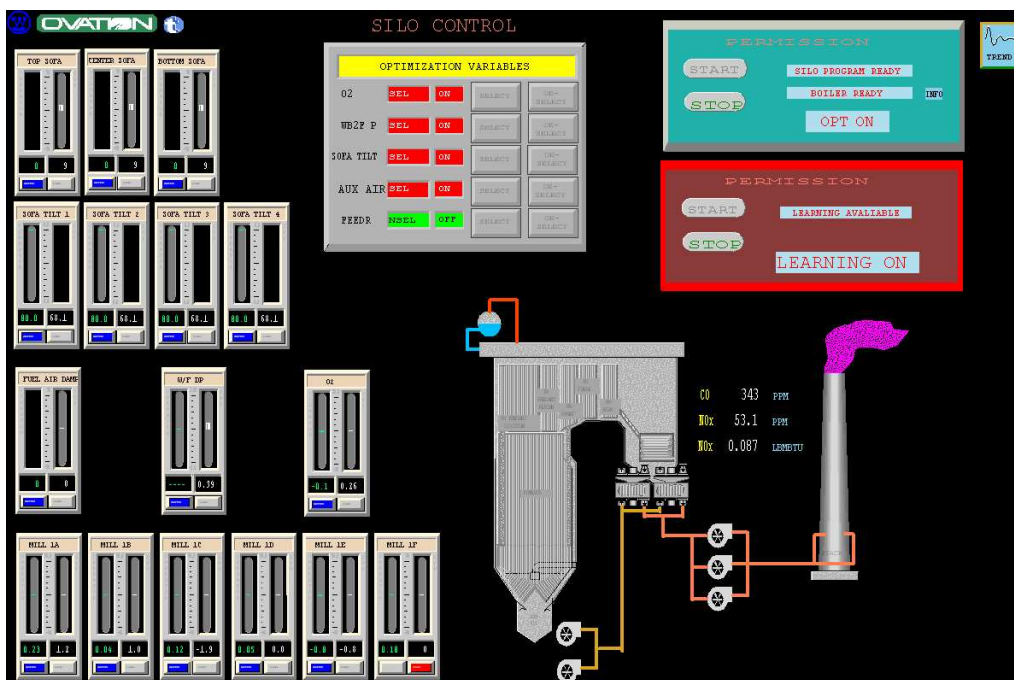
**CAPACITY - 4,158,619 LB PER HR AT 2620 PSIG AND 1005 F TEMP - REHEAT 1005 F  
DESIGNED AND MANUFACTURED BY COMBUSTION ENGINEERING, INC.  
SARGENT & LUNDY - CONSULTING ENGINEERS**

Rysunek 11.1 Schemat budowy kotłów energetycznych w rozpatrywanej elektrowni.

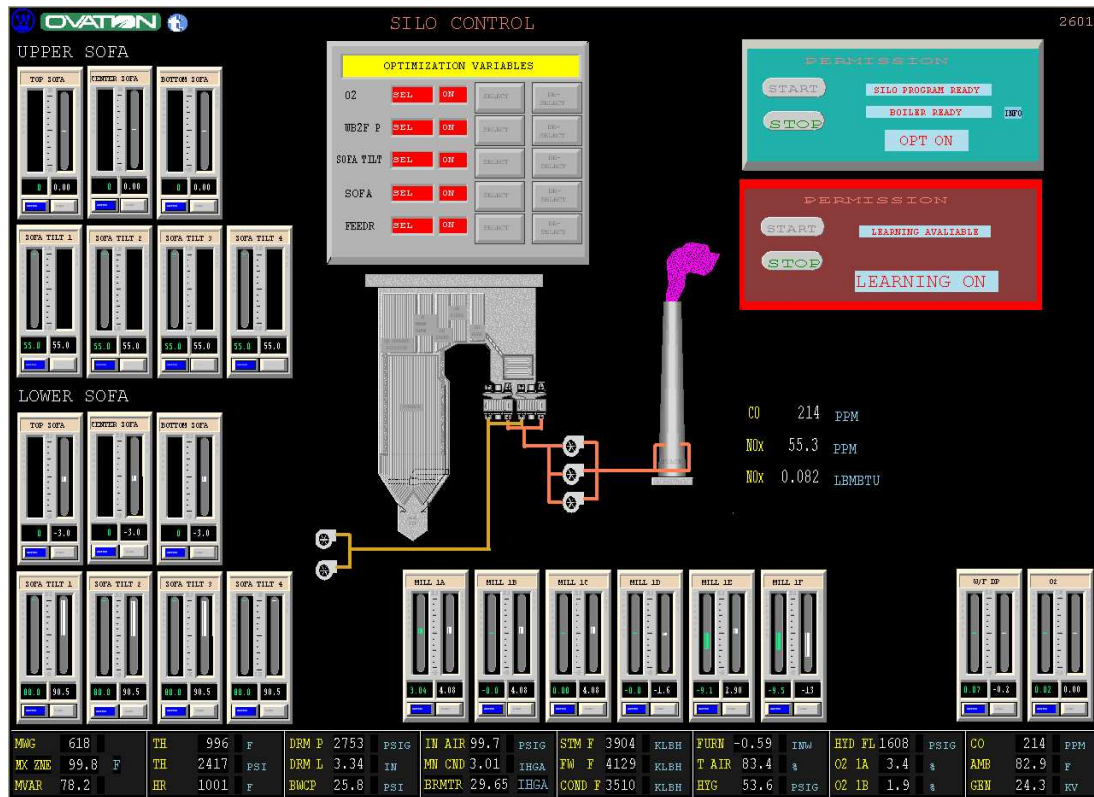


Rysunek 11.2 Rozmieszczenie palników, klap powietrza wtórnego, klap CCOFA i SOFA na bloku nr. 1.

Parts Per Million). Tak więc system SILO powinien dążyć do utrzymania jak najniższej wartości emisji  $\text{NO}_x$  pod warunkiem, że wartość emisji CO nie przekroczy 400 PPM. Przed przystąpieniem do konfiguracji systemu SILO zidentyfikowano zestaw urządzeń wykonawczych, które będą znajdować się pod kontrolą SILO. Następnie zmodyfikowano układy sterowania tych urządzeń tak aby umożliwić przejęcie kontroli przez system SILO (patrz rozdział 4). W systemie DCS stworzono również logikę załączenia/wyłączenia systemu SILO i grafiki umożliwiające sprawowanie kontroli przez operatora nad systemem SILO. Główna grafika załączenia systemu SILO na bloku pierwszym została przedstawiona na rys. 11.3, a grafika załączenia SILO na bloku drugim została pokazana na rys. 11.4. Wykorzystując grafiki przedstawione na rys. 11.3 i 11.4 operator może szybko włączyć i wyłączyć moduł optymalizacji i/lub uczenia systemu SILO (patrz rozdział 4). Ponadto możliwe jest włączenie i wyłączenie wybranej grupy urządzeń z pod kontroli SILO.



Rysunek 11.3 Grafika załączenia SILO na bloku pierwszym.



Rysunek 11.4 Grafika załączenia SILO na bloku drugim.

### 11.1.1 Wdrożenie SILO na bloku pierwszym

Pierwsze próbne wdrożenie systemu SILO na bloku pierwszym zostało przeprowadzone w styczniu 2007 roku. Uzyskano wówczas bardzo dobre rezultaty. Po zakończeniu tego próbnego wdrożenia inżynierowie z firmy Alstom, na podstawie sterowań generowanych przez system SILO dokonali istotnych zmian w układzie regulacji bezpośredniej. Zmianie uległy zależności funkcyjne wartości zadanych dla urządzeń wykonawczych od aktualnego stanu procesu, oraz zakres pracy regulatora tlenu i różnicy ciśnienia między komorą spalania i kolektorem powietrza wtórnego. W marcu 2007, po zakończeniu strojenia układu regulacji bezpośredniej, zarząd elektrowni zaproponował przeprowadzenie ponownego wdrożenia SILO na bloku pierwszym. W niniejszym rozdziale przedstawiono wyniki ostatecznego wdrożenia systemu SILO przeprowadzone w marcu 2007. Podczas ponownej instalacji zrezygnowano z kontrolowania poziomu otwarcia klap SOFA i CCOFA. Przeprowadzone testy, oraz uwagi operatorów wyraźnie pokazały, że na bloku pierwszym należy prowadzić proces spalania mając całkowicie otwarte wszystkie poziomy klap SOFA i zamknięte obydwie poziomy klap CCOFA. Na pierwszym bloku omawianej elektrowni SILO kontrolowało następujące wielkości:

- wartość zadana regulatora tlenu;
- wartość zadana regulatora różnicy ciśnień między komorą spalania i kolektorem powietrza wtórnego;
- kąty ustawienia dysz klap SOFA w każdym rogu kotła (cztery wielkości);
- prędkości podajników węgla do każdego z sześciu młynów węglowych.

Aby zredukować wymiar zadania optymalizacji utworzono *wirtualne* zmienne sterujące. Zamiast niezależnego sterowania kątem ustawienia dysz klap SOFA wprowadzono następujące trzy zmienne wirtualne:

- średni poziom ustawienia kątów dysz klap SOFA dla wszystkich czterech rogów komory spalania;
- różnica kąta dysz klap SOFA między pierwszym i trzecim rogiem komory spalania;
- różnica kąta dysz klap SOFA między drugim i czwartym rogiem komory spalania.



Ponadto należało spełnić warunek, że system SILO nie będzie zmieniał sumy podawanego do kotła paliwa. W związku z tym ustalono, że system SILO będzie kontrolował prędkość trzech podajników węgla związanych z młynami węglowymi zasilającymi palniki znajdujące się w trzech najwyższych rzędach komory spalania. Podajniki węgla związane z dolnymi rzędami palników będą kompensować zmiany prędkości górnych podajników w taki sposób aby suma paliwa dostarczanego do kotła zależała wyłącznie od wartości zadanych generowanych przez podstawowy układ regulacji.

*Wpięcia* systemu SILO w podstawowy układ sterowania zostały przeprowadzone w taki sposób, że:

- w układzie regulacji poziomu tlenu w spalinach SILO wprowadza poprawkę do wartości zadanej regulatora tlenu (wpięcie typu A na rys. 4.9 w rozdziale 4);
- w układzie regulacji różnicy ciśnień między komorą spalania i kolektorem powietrza wtórnego SILO wprowadza poprawkę do wartości zadanej regulatora różnicy ciśnień (wpięcie typu A na rys. 4.9 w rozdziale 4);
- w układzie regulacji kątów ustawienia dysz klap SOFA SILO oblicza wartość zadaną ustawienia kątów dysz klap SOFA (wpięcie typu B na rys. 4.9 w rozdziale 4);
- w układzie regulacji podajników węgla SILO wprowadza poprawkę do wartości zadanej prędkości podajników węgla (wpięcie typu A na rys. 4.9 w rozdziale 4).

Po wprowadzeniu wirtualnych zmiennych sterujących i uwzględnieniu sposobu wpięcia, wektor sterowań  $x$  składa się z następujących elementów:

- korekta wartości zadanej regulatora tlenu;
- korekta wartości zadanej regulatora różnicy ciśnień między komorą spalania i kolektorem powietrza wtórnego;
- wartość zadana średniego poziomu ustawienia kątów dysz klap SOFA dla wszystkich czterech rogów komory spalania;
- wartość zadana różnicy kąta dysz klap SOFA między pierwszym i trzecim rogiem komory spalania;
- wartość zadana różnicy kąta dysz klap SOFA między drugim i czwartym rogiem komory spalania;

- korekta prędkości podajnika węgla związanego z palnikami w rzędzie D;
- korekta prędkości podajnika węgla związanego z palnikami w rzędzie E;
- korekta prędkości podajnika węgla związanego z palnikami w rzędzie F.

Wektor optymalizowanych wyjść obiektu składa się z następujących sygnałów:

- wartość emisji CO mierzona w kominie;
- wartość emisji  $\text{NO}_x$  mierzona w kominie.


Wektor zakłóceń mierzonych  $z$  składa się z następujących sygnałów:

- obciążenie bloku;
- zmierzona prędkość podajnika węgla związanego z palnikami w rzędzie A;
- zmierzona prędkość podajnika węgla związanego z palnikami w rzędzie B;
- zmierzona prędkość podajnika węgla związanego z palnikami w rzędzie C;
- zmierzona prędkość podajnika węgla związanego z palnikami w rzędzie D;
- zmierzona prędkość podajnika węgla związanego z palnikami w rzędzie E;
- zmierzona prędkość podajnika węgla związanego z palnikami w rzędzie F;
- kąt ustawień dysz palników.

Podczas wstępnych obserwacji zauważono, że odpowiedź obiektu na zmianę sterowania jest stosunkowo długa. Ustalono, że okres optymalizacji wynosi 15 minut. Tak więc w czasie normalnej pracy kotła, system SIŁO oblicza nowy wektor sterowań z okresem piętnastominutowym. Ponadto ustalono, że limfocyty zgromadzone w pamięci immunologicznej będą rozpoznawały patogen tylko wówczas jeżeli bezwzględna różnica między aktualną i zapisaną w limfocycie wartością obciążenia bloku będzie mniejsza niż 40 MW i jednocześnie konfiguracja pracujących młynów węglowych zapisana w limfocycie będzie odpowiadała aktualnej konfiguracji.

Wdrożenie systemu SIŁO na bloku pierwszym trwało 12 dni roboczych (nie uwzględniono czasu poświęconego na budowę wpięć i grafik operatorskich). Podczas pierwszego tygodnia system został zainstalowany i skonfigurowany. Stworzono wirtualne zmienne sterujące i algorytm kompensowania zmian prędkości podajników węgla.

Szóstego dnia wdrożenia system SILO został uruchomiony. Podczas pierwszego dnia pracy system przez większość czasu znajdował się w warstwie optymalizacji stochastycznej. Po zebraniu wystarczającej ilości informacji o procesie w systemie SILO zaczęły dominować wtórne reakcje immunologiczne (praca w warstwie optymalizacji na modelu mieszanym lub globalnym). Po 5 dniach od uruchomienia przeprowadzono testy odbiorcze systemu SILO. Każdy test zaczynał się w stanie, w którym system SILO kontrolował proces. Następnie system SILO był wyłączany. Po odpowiednio długim okresie czasu system SILO ponownie był włączany. Każdy test przeprowadzany był przy stałym poziomie mocy. Zostały wykonane trzy testy. Każdy test odbywał się innego dnia. Testy przeprowadzano przy obciążeniu bloku równym lub nieznacznie mniejszym od nominalnego (615 MW). Ze względu na harmonogram produkcji niemożliwe było przeprowadzenie takich testów na innych poziomach mocy.




Rysunek 11.5 Test z dnia 26 marca 2007 r.

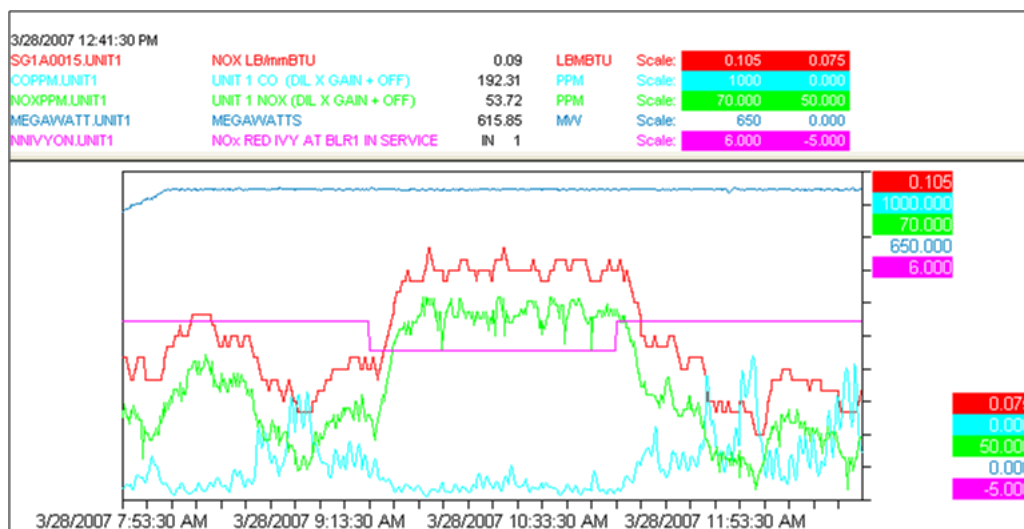
Oznaczenia sygnałów na rysunkach 11.5-11.7:

- Kolorem niebieskim oznaczono obciążenie bloku [MW];
- Kolorem błękitnym oznaczono wartość emisji CO [PPM];
- Kolorem zielonym oznaczono wartość emisji NO<sub>x</sub> [PPM];
- Kolorem czerwonym oznaczono wartość emisji NO<sub>x</sub> [LB/mmBTU<sup>1</sup>];

<sup>1</sup> skrót *LB* oznacza funty (jednostka masy), a skrót *mmBTU* oznacza milion *BTU*, gdzie *BTU* to jednostka energii tzw. *british thermal unit*




Rysunek 11.6 Test z dnia 27 marca 2007 r.




Rysunek 11.7 Test z dnia 28 marca 2007 r.

- Kolorem różowym oznaczono sygnał statusu włączenia (poziom wysoki) i wyłączenia (poziom niski) systemu SILO.

Na rysunkach 11.8-11.10 przedstawiono uśrednione wyniki przeprowadzonych testów. Poziom KPI (Key Performance Index) oznacza maksymalny dopuszczalny poziom emisji  $\text{NO}_x$  wyznaczony przez zarząd koncernu, do którego należy omawiana elektrownia.




Rysunek 11.8 Średnia wartość emisji  $\text{NO}_x$  [LB/mmBTU]



Rysunek 11.9 Średnia wartość emisji  $\text{NO}_x$  [PPM]

Analizując rys. 11.10 widać, że średnia wartość emisji CO podczas przeprowadzonych testów nie przekroczyła poziomu 206.7 PPM. Chwilowe wartości emisji CO



Rysunek 11.10 Średnia wartość emisji CO [PPM]


nie przekraczały poziomu 400 PPM. Widać więc, że SILO spełnia warunek narzucony na emisję CO. Należy zwrócić uwagę, że omawiana elektrownia nie płaci kar za nadmierną emisję CO, tak więc system SILO może powodować wyższą emisję CO w porównaniu do układu regulacji bezpośredniej pod warunkiem, że emisja  $\text{NO}_x$  będzie niższa i spełnione będzie ograniczenie na poziom emisji CO. Podczas przeprowadzonych testów osiągnięto następującą względną poprawę emisji  $\text{NO}_x$ :

- test z dnia 26 marzec 2007 - zmniejszenie emisji  $\text{NO}_x$  o 13.9 %;
- test z dnia 27 marzec 2007 - zmniejszenie emisji  $\text{NO}_x$  o 12.7 %;
- test z dnia 28 marzec 2007 - zmniejszenie emisji  $\text{NO}_x$  o 10.6 %.

Tak więc podczas pracy systemu SILO emisja  $\text{NO}_x$  jest zredukowana o ok. 12.4 % w stosunku do układu regulacji bezpośredniej. Tak dobry wynik skłonił zarząd elektrowni do podjęcia decyzji o implementacji systemu SILO na bloku drugim.

Podczas implementacji systemu SILO na bloku drugim (czerwiec 2007 r.) wykonano również eksperyment na bloku pierwszym polegający na porównaniu wyników osiąganych przez system SILO z wynikami osiąganymi przez podstawowy układ regulacji. Należy zauważyć, że eksperyment ten został przeprowadzony trzy miesiące po zakończeniu wdrożenia na bloku pierwszym. Test wykonano w sytuacji, gdy jeden z młynów węglowych uległ uszkodzeniu i pozostałe pięć młynów było maksymalnie obciążanych po to aby osiągnąć nominalną moc bloku (615 MW). Tak więc ze względu na konieczności maksymalnego obciążenia młynów węglowych, nie było możliwości

kontrolowania podajników węgla. Była to nowa sytuacja dla SILO, jednak system w ciągu jednej nocy zdobył wystarczającą wiedzę, aby móc prowadzić obiekt w sposób umożliwiający spełnienie celów optymalizacji.



Rysunek 11.11 Test porównawczy systemu SILO i układu regulacji bezpośredniej.

Na rysunku 11.11 przyjęto następujące oznaczenia:

- Kolor zielony oznacza sygnał obciążenia bloku [MW];
- Kolor błękitny oznacza sygnał emisji CO [PPM];
- Kolor czerwony oznacza sygnał emisji  $\text{NO}_x$  [LB/mmBTU];
- Kolor niebieski oznacza sygnał statusu włączenia (poziom wysoki) i wyłączenia (poziom niski) systemu SILO.

Na rys. 11.11 wyraźnie widać, że wyłączenie systemu SILO powoduje nieznaczne obniżenie emisji  $\text{NO}_x$  przy jednoczesnym bardzo dużym zwiększeniu emisji CO. Widać, że po drugim wyłączeniu systemu SILO emisja CO zwiększyła się do poziomu przekraczającego 1000 PPM co jest sytuacją niedopuszczalną. Podczas pracy systemu SILO emisja CO utrzymywana jest poniżej narzuconego przez zarząd elektrowni ograniczenia wynoszącego 400 PPM. Należy również zwrócić uwagę, że pomimo nieznacznie wyższej emisji  $\text{NO}_x$  w stosunku do układu regulacji bezpośredniej, emisja

tego związku utrzymywana jest na równie niskim poziomie jak podczas testów odbiorczych. Przeprowadzony test potwierdza, że po trzech miesiącach od pierwszego uruchomienia:

- System SILO jest w stanie efektywnie adaptować się do zmieniających się warunków pracy (awaria młyna węglowego, wyłączenie z pod kontroli SILO podajników węgla);
- System SILO osiąga zdecydowanie lepsze rezultaty w porównaniu do podstawowego układu regulacji w kontekście założonych celów optymalizacji (system SILO potrafi utrzymać emisję CO poniżej ograniczenia narzuconego przez zarząd elektrowni).

We wrześniu 2007, a zatem 6 miesięcy po pierwszym uruchomieniu systemu SILO, opublikowany został raport EPA (ang. U.S. Environmental Protection Agency), w którym stwierdzono, że w przedziale czasowym od początku czerwca 2007 do końca sierpnia 2007 blok pierwszy rozpatrywanej w niniejszym rozdziale elektrowni zajął drugie miejsce w USA pod względem najniższej emisji  $\text{NO}_x$  wśród bloków pozbawionych katalizatorów wtórnie redukujących emisję  $\text{NO}_x$  (patrz rozdział 10). Jest to dodatkowe potwierdzenie skuteczności systemu SILO do optymalizacji procesu spalania w kotle energetycznym.


Na zakończenie omawiania wyników pracy SILO na bloku pierwszym przedstawiono wyniki porównania rezultatów osiąganych przez system SILO i regulator predykcyjny z rozmytym modelem obiektu. Porównanie to zostało przeprowadzone w styczniu 2007 podczas pierwszego próbnego wdrożenia systemu SILO. Przed wdrożeniem systemu SILO blok pierwszy był kontrolowany przez regulator predykcyjny. Ostatnie prace związane ze strojeniem modeli tego regulatora były przeprowadzane w listopadzie 2006 roku. Analizując wyniki tego testu należy mieć na uwadze, że:

- Modele używane przez regulator MPC nie były od 3 miesięcy uaktualniane;
- W momencie przeprowadzania testów system SILO działał od zaledwie tygodnia i przez zdecydowaną większość czasu moc bloku znajdowała się w przedziale 600 - 615 MW. System SILO nie miał więc możliwości zdobyć wiedzy o pracy kotła w innym zakresie obciążenia bloku.


Aby eksperyment ten był reprezentatywny należałoby przeprowadzić testy bezpośrednio po skonfigurowaniu regulatora MPC i po upływie miesiąca od zainstalowania



systemu SILO, tak aby system miał czas nauczyć się procesu. Ze względu na zewnętrzne czynniki uniemożliwiające osiągnięcie takich warunków, wyniki przeprowadzonego eksperymentu należy traktować jedynie szacunkowo.




Rysunek 11.12 Porównanie emisji  $\text{NO}_x$  [LB/mmBTU]



Rysunek 11.13 Porównanie emisji  $\text{NO}_x$  [PPM]

Analizując przedstawione na rys. 11.12-11.14 wyniki wyraźnie widać, że emisja  $\text{NO}_x$  jest najwyższa, gdy system SILO i regulator predykcyjny są wyłączone, a za sterowanie procesem odpowiedzialny jest jedynie podstawowy układ sterowania. W porównaniu z regulatorem predykcyjnym, system SILO utrzymuje wyraźnie mniejszą emisję



Rysunek 11.14 Porównanie emisji CO [PPM]

$\text{NO}_x$  w zakresie obciążenia bloku 593 - 618 MW. W niższym zakresie mocy regulator MPC utrzymuje niższą emisję  $\text{NO}_x$ , co można wytłumaczyć faktem, że system SILO nie miał możliwości zdobyć wiedzy o procesie przy nieco mniejszych wartościach obciążenia bloku. Analizując emisję CO widać, że SILO utrzymuje mniejszą emisję CO w porównaniu do regulatora predykcyjnego w całym zmierzonym podczas trwania eksperymentu zakresie pracy bloku. Gdy proces jest kontrolowany jedynie przez układy regulacji podstawowej emisja CO w porównaniu do SILO jest większa w zakresie obciążenia 608-618 MW i mniejsza poniżej tego zakresu. W całym zmierzonym zakresie obciążenia bloku średnia emisja CO w przypadku SILO nie przekroczyła 200 PPM, dzięki czemu spełnione zostały ograniczenia narzucone na emisje CO przez zarząd elektrowni. Ponieważ blok pierwszy rozpatrywanej elektrowni przez zdecydowaną większość czasu pracuje przy nominalnym obciążeniu 615 MW, najważniejsze są rezultaty osiągnięte dla tej właśnie mocy. Wyniki te zostały przedstawione w tabeli 11.1.

Wyniki eksperymentu pokazują, że SILO stanowi alternatywę dla regulatorów MPC. Niestety nie jest możliwe przeprowadzenie reprezentatywnych testów porównawczych regulatora predykcyjnego i systemu SILO w szerszym zakresie obciążenia bloku. Główną przeszkodą jest wysoki koszt wdrożenia regulatora predykcyjnego. Drugą istotną przeszkodą jest konieczność wyrażenia zgody na wdrożenie regulatora predykcyjnego i systemu SILO przez zarząd elektrowni. Należy zwrócić uwagę na fakt,

Tabela 11.1 Wyniki SILO przy nominalnym obciążeniu bloku (615 MW)

Redukcja emisji NO <sub>x</sub>	Redukcja emisji CO
10 % w stosunku do regulacji podstawowej	27 % w stosunku do regulacji podstawowej
1.9 % w stosunku do regulatora MPC	31.2 % w stosunku do regulatora MPC


że wdrożenie regulatora predykcyjnego wiąże się z koniecznością zmiany harmonogramu produkcji energii przez elektrownię na czas testów parametrycznych, co generuje straty finansowe. Jednym z argumentów przemawiających za zakupem systemu SILO jest brak konieczności przeprowadzania takich testów. Tak więc posiadając już system SILO, elektrownia nie jest zainteresowana wdrożeniem dodatkowo regulatora predykcyjnego, ponieważ może to spowodować zauważalne straty finansowe.

### 11.1.2 Wdrożenie SILO na bloku drugim

Wdrożenie SILO na drugim bloku omawianej elektrowni nastąpiło w czerwcu 2007 roku. Wdrożenie to trwało 11 dni roboczych. Niestety podczas wdrażania systemu SILO, układ regulacji bloku drugiego był jeszcze modyfikowany i dostrajany, przez co warunki pracy bloku były bardzo niekorzystne w kontekście zdobywania wiedzy o procesie przez system SILO. Sygnał obciążenia bloku, a przez to również sygnał emisji NO<sub>x</sub> i CO charakteryzowały się wysokimi oscylacjami (patrz rys. 11.15). Ponadto obiekt słabiej reagował na wymuszenia podawane na wejścia sterowane.

Blok drugi posiada dodatkowe trzy poziomy klap SOFA. Po wprowadzeniu wirtualnych zmiennych sterujących i po uwzględnieniu sposobu wpięcia systemu SILO, wektor sterowań  $x$  składa się z następujących elementów:

- korekta wartości zadanej regulatora tlenu;
- korekta wartości zadanej regulatora różnicy ciśnień między komorą spalania i kolektorem powietrza gorącego;
- wartość zadana średniego poziomu ustawienia kątów dysz klap SOFA dla wszystkich czterech rogów komory spalania, dla trzech dolnych poziomów klap SOFA;



Rysunek 11.15 Oscylacje sygnału obciążenia bloku związane z niepoprawnym skonfigurowaniem układu regulacji ciśnienia zaworów turbiny.

- wartość zadana średniego poziomu ustawienia kątów dysz klap SOFA dla wszystkich czterech rogów komory spalania, dla trzech górnych poziomów klap SOFA;
- korekta wartości zadanej średniego otwarcia klap SOFA w trzech dolnych rzędach;
- korekta wartości zadanej średniego otwarcia klap SOFA w trzech górnych rzędach;
- wartość zadana różnicy między otwarciem klapy SOFA znajdującej się najniżej i najwyżej w grupie trzech dolnych rzędów klap SOFA;
- wartość zadana różnicy między otwarciem klapy SOFA znajdującej się najniżej i najwyżej w grupie trzech górnych rzędów klap SOFA;
- korekta prędkości podajnika węgla związanego z palnikami w rzędzie D;
- korekta prędkości podajnika węgla związanego z palnikami w rzędzie E;
- korekta prędkości podajnika węgla związanego z palnikami w rzędzie F.

Ustalono, że podobnie jak na bloku pierwszym system SILO będzie kontrolował prędkość trzech podajników węgla związanych z młynami węglowymi zasilającymi palniki znajdujące się w trzech najwyższych rzędach komory spalania. Podajniki węgla związane z dolnymi rzędami palników będą kompensować zmiany prędkości górnych podajników w taki sposób aby suma paliwa dostarczanego do kotła zależała wyłącznie od wartości zadanych generowanych przez podstawowy układ regulacji.

Wektor optymalizowanych wyjść obiektu składa się z następujących sygnałów:

- wartość emisji CO mierzona w kominie;
- wartość emisji  $\text{NO}_x$  mierzona w kominie.

Wektor zakłóceń mierzonych z składa się z następujących sygnałów:


- obciążenie bloku;
- zmierzona prędkość podajnika węgla związanego z palnikami w rzędzie A;
- zmierzona prędkość podajnika węgla związanego z palnikami w rzędzie B;
- zmierzona prędkość podajnika węgla związanego z palnikami w rzędzie C;
- zmierzona prędkość podajnika węgla związanego z palnikami w rzędzie D;
- zmierzona prędkość podajnika węgla związanego z palnikami w rzędzie E;
- zmierzona prędkość podajnika węgla związanego z palnikami w rzędzie F;
- kąt ustawień dysz palników.

Ustalono, że okres optymalizacji wynosi 15 minut.


Pierwsze cztery dni wdrożenia upłynęły na konfiguracji systemu SILO. Następnie system został uruchomiony. Po upływie pięciu dni od pierwszego uruchomienia, mimo bardzo niekorzystnych warunków do nauki procesu, dokonano eksperymentu porównującego wyniki osiągnięte przez SILO i przez układ regulacji podstawowej. Testy były przeprowadzane w podobny sposób jak na bloku pierwszym. Starano się, aby podczas testu obciążenie bloku było stałe, lub oscylowało wokół stałej wartości, równej nominalnemu obciążeniu bloku 615 MW.

Oznaczenia sygnałów na rysunkach 11.16-11.18:


- kolorem czerwonym oznaczono obciążenie bloku [MW],
- kolorem zielonym oznaczono wartość emisji CO [PPM],
- kolorem niebieskim oznaczono wartość emisji  $\text{NO}_x$  [LB/mmBTU],
- kolorem błękitnym oznaczono sygnał statusu włączenia (poziom wysoki) i wyłączenia (poziom niski) systemu SILO.




Rysunek 11.16 Test porównawczy z dnia 18 czerwca 2007.




Rysunek 11.17 Test porównawczy z dnia 19 czerwca 2007.



Rysunek 11.18 Test porównawczy z dnia 20 czerwca 2007.



Rysunek 11.19 Porównanie emisji NO<sub>x</sub> [LB/mmBTU].



Rysunek 11.20 Porównanie emisji CO [PPM].

Na rys. 11.19 i 11.20 przedstawiono uśrednione wyniki przeprowadzonych eksperymentów. Osiągnięto następującą względną poprawę emisji  $\text{NO}_x$ :

- test z dnia 18 czerwca 2007 - zmniejszenie emisji  $\text{NO}_x$  o 4.3 %;
- test z dnia 19 czerwca 2007 - zmniejszenie emisji  $\text{NO}_x$  o 6.0 %;
- test z dnia 20 czerwca 2007 - zmniejszenie emisji  $\text{NO}_x$  o 12.1 %.

Widać zatem, że gdy system SILO steruje procesem emisja  $\text{NO}_x$  jest zmniejszona średnio o 7.5 %. Emisja CO jest wyższa niż w przypadku podstawowego układu regulacji. Pomimo tego średnia emisja CO jest mniejsza niż ograniczenie emisji CO narzucone przez zarząd elektrowni. Ze względu na bardzo duże oscylacje sygnału emisji CO, chwilowe wartości emisji CO mogą czasami nieznacznie przekroczyć narzucone ograniczenia.

Otrzymane wyniki świadczą o tym, że system SILO potrafi zredukować emisję  $\text{NO}_x$  spełniając tym samym cele zdefiniowane przez klienta. Należy jednak pamiętać, że system SILO nie miał wystarczająco dużo czasu ani zadowalających warunków pracy kotła aby zdobyć bardziej szczegółową wiedzę o procesie. Należy spodziewać się, że wraz z upływem czasu osiągnane rezultaty będą coraz lepsze.

We wrześniu 2007, a zatem 3 miesiące po pierwszym uruchomieniu systemu SILO na bloku drugim, opublikowany został raport EPA (ang. U.S. Environmental Protection Agency), w którym stwierdzono, że w przedziale czasowym od początku czerwca 2007 do końca sierpnia 2007 blok drugi rozpatrywanej elektrowni zajął trzecie miejsce w USA pod względem najmniejszej emisji  $\text{NO}_x$  wśród bloków pozbawionych katalizatorów wtórnie redukujących emisję  $\text{NO}_x$  (patrz rozdział 10). Jest to dodatkowe potwierdzenie skuteczności systemu SILO w zastosowaniu do optymalizacji procesu spalania w kotle energetycznym. Podczas wizyty autora w firmie Emerson Process Management w grudniu 2007 roku połączono się zdalnie z omawianą elektrownią i potwierdzono, że system SILO cały czas w trybie ciągłym steruje procesem spalania na obu blokach energetycznych.



## 11.2 Wdrożenie systemu SILO w jednej z polskich elektrowni

W rozdziale tym zostało omówione wdrożenie systemu SILO w jednej z polskich elektrowni systemowych. Paliwem spalonym w tej elektrowni jest węgiel kamienny. Elektrownia składa się z trzech bloków energetycznych:

- blok nr. 1 – moc osiągalna 221 MW,
- blok nr. 2 – moc osiągalna 200 MW,
- blok nr. 3 – moc osiągalna 226 MW.

W każdym z tych bloków proces spalania zachodzi w kotle OP-650-K. Jest to opromieniowany, wysokoprężny, dwuciągowy kocioł wiszący. Każdy blok posiada jeden walczak. W kotle zainstalowano trójstopniowy przegrzewacz pary świeżej i trójstopniowy przegrzewacz pary wtórnej.

W przedniej ścianie kotła znajdują się 24 palniki pyłowo-wirowe, rozmieszczone po sześć palników w każdym z czterech rzędów. Mieszanka paliwowo-powietrzna z każdego z czterech młynów węglowych rozdzielana jest na zubożoną i wzbogaconą. Do pierwszego i drugiego rzędu palników dostarczana jest mieszanka zubożona. Do trzeciego i czwartego rzędu palników dostarczana jest mieszanka wzbogacona. Na przeciwległej ścianie w stosunku do palników znajdują się dysze OFA. Operatorzy ręcznie sterują otwarciem klap powietrza wtórnego oraz otwarciem klap OFA.

System DCS zainstalowany na bloku pierwszym i trzecim to WDPF II firmy Westinghouse, oparty na systemie Solaris. Na bloku drugim zainstalowany jest system Ovation 2.1 oparty na systemie Solaris. System SILO jest zainstalowany na osobnym komputerze opartym na systemie Red Hat Linux 5.

Na każdym z trzech bloków cele optymalizacji systemu SILO zostały zdefiniowane następująco:

- utrzymanie pięciominutowych średnich emisji CO, mierzonych za obrotowym podgrzewaczem powietrza, poniżej poziomu  $250 \text{ mg/Nm}^3$ ;
- utrzymanie godzinowych średnich emisji  $\text{NO}_x$ , mierzonych za obrotowym podgrzewaczem powietrza, poniżej poziomu  $500 \text{ mg/Nm}^3$ ;
- utrzymanie temperatury pary świeżej na poziomie  $540 \pm 5 \text{ }^\circ\text{C}$ ;

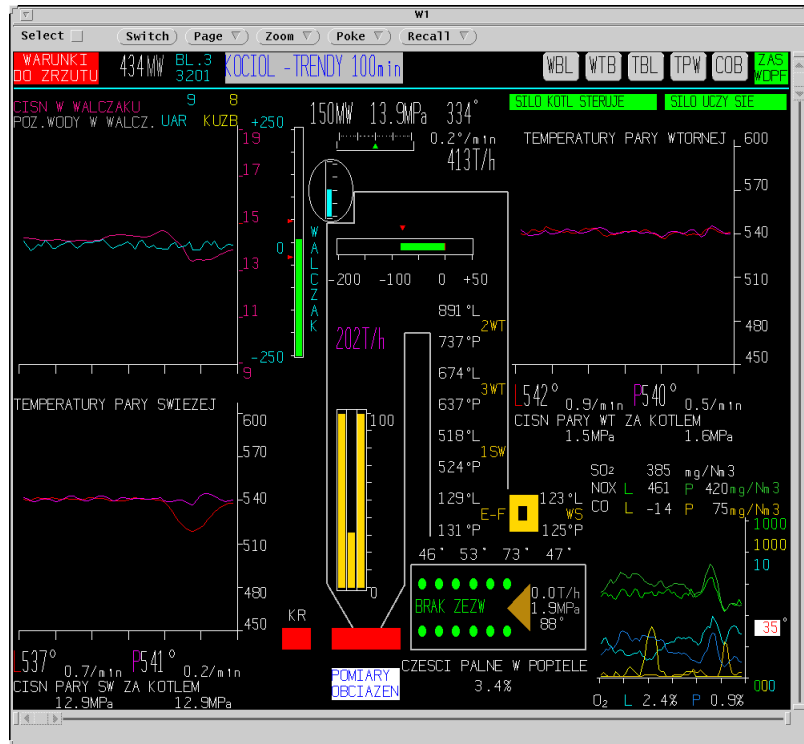
- utrzymanie części palnych w popiele poniżej 5 %;
- utrzymanie temperatur spalin poniżej 140 °C.

Ustalono, że wszystkie wpięcia systemu SILO w układ regulacji podstawowej będą przeprowadzone jak w wariancie B na rys. 4.9 w rozdziale 4. Logika załączenia systemu SILO została zbudowana zgodnie z opisem przedstawionym w rozdziale 4. Stworzona grafika operatorska umożliwia włączenie/wyłączenie optymalizacji SILO oraz włączenie/wyłączenie wybranych grup urządzeń z pod nadzoru SILO (patrz rys. 11.21).



Rysunek 11.21 Grafika operatorska systemu SILO na bloku trzecim.

Jednym z celów optymalizacji było utrzymanie temperatur pary świeżej na poziomie 540 °C. Należy zauważyć, że w przypadku gdy temperatura pary świeżej przekroczy pewną wartość graniczną uruchamiane są wtryski schładzające parę. Powyżej pewnego poziomu temperatury pary system SILO nie obserwuje reakcji temperatur pary na zmianę sterowania, ponieważ wtryski starają skompensować tą zmianę sterowania. Aby wyeliminować tę nieliniowość, nie zwiększając jednocześnie wymiaru zadania optymalizacji, stworzono zmienną reprezentującą wirtualną temperaturę



Rysunek 11.22 Główna grafika kotła na bloku trzecim.

pary. Stosując prostą liniową zależność funkcyjną dokonywana jest estymacja temperatury pary świeżej na podstawie obciążenia wtrysków znajdujących się między pierwszym i drugim, oraz drugim i trzecim stopniem przegrzewaczy. W przypadku, gdy obciążenie wtrysków jest bliskie zera, zmierzona temperatura pary świeżej jest równa estymowanej wirtualnej temperaturze pary świeżej.

Ustalono, że wektor sterowań  $x$  na każdym z bloków składać się będzie z następujących elementów:

- wartość zadana otwarcia klap powietrza wtórnego w rzędzie pierwszym po lewej stronie kotła;
- wartość zadana otwarcia klap powietrza wtórnego w rzędzie pierwszym po prawej stronie kotła;
- wartość zadana otwarcia klap powietrza wtórnego w rzędzie drugim po lewej stronie kotła;
- wartość zadana otwarcia klap powietrza wtórnego w rzędzie drugim po prawej stronie kotła;
- wartość zadana otwarcia klap powietrza wtórnego w rzędzie trzecim po lewej stronie kotła;
- wartość zadana otwarcia klap powietrza wtórnego w rzędzie trzecim po prawej stronie kotła;
- wartość zadana otwarcia klap powietrza wtórnego w rzędzie czwartym po lewej stronie kotła;
- wartość zadana otwarcia klap powietrza wtórnego w rzędzie czwartym po prawej stronie kotła;
- wartość zadana otwarcia klap OFA po lewej stronie kotła;
- wartość zadana otwarcia klap OFA po prawej stronie kotła;
- wartość zadana poziomu tlenu w spalinach.

Wektor optymalizowanych wyjść składa się z 9 elementów:

- poziom emisji CO - strona lewa;

- poziom emisji CO - strona prawa;
- poziom emisji NO<sub>x</sub> - strona lewa;
- poziom emisji NO<sub>x</sub> - strona prawa;
- estymowana temperatura pary świeżej - strona lewa;
- estymowana temperatura pary świeżej - strona prawa;
- temperatura spalin przed elektrofiltrem - strona lewa;
- temperatura spalin przed elektrofiltrem - strona prawa;
- zawartość części palnych w popiele.

Wektor zakłóceń mierzonych z składa się z następujących sygnałów:

- obciążenie bloku;
- zmierzona prędkość podajnika węgla do młyna 1;
- zmierzona prędkość podajnika węgla do młyna 2;
- zmierzona prędkość podajnika węgla do młyna 3;
- zmierzona prędkość podajnika węgla do młyna 4;
- estymowana odchyłka kaloryczności paliwa.

Na podstawie obserwacji odpowiedzi obiektu ustalono, że okres optymalizacji na każdym bloku wynosi 8 minut. Ponadto ustalono, że limfocyty zgromadzone w pamięci immunologicznej będą rozpoznawały patogen jedynie w sytuacji, w której będzie spełniony każdy z przedstawionych warunków:

- Bezwzględna różnica między aktualną i zapisaną w limfocycie wartością obciążenia bloku będzie mniejsza niż 25 MW;
- Bezwzględna różnica między aktualną i zapisaną w limfocycie wartością estymowanej odchyłki kaloryczności paliwa będzie mniejsza niż 25 % zakresu odchyłki;
- Konfiguracja pracujących młynów węglowych zapisana w limfocycie będzie odpowiadała aktualnej konfiguracji pracy młynów;

- Jeżeli aktualny poziom emisji CO nie przekracza  $100 \text{ mg/Nm}^3$  to wartość emisji CO zapisana w limfocycie musi wynosić mniej niż  $150 \text{ mg/Nm}^3$ . Jeżeli natomiast aktualna wartość emisji CO jest wyższa niż  $100 \text{ mg/Nm}^3$ , to bezwzględna różnica między aktualną i zapisaną w limfocycie wartością emisji CO musi być mniejsza niż  $150 \text{ mg/Nm}^3$ .

Na każdym bloku w specjalnym module reprezentującym wrodzony układ odpornościowy, zaimplementowano pewne mechanizmy obronne polegające na zamykaniu klap powietrza wtórnego związanych z wyłączonymi młynami węglowymi.

W połowie 2006 roku pierwsza wersja systemu SILO została wdrożona na każdym z trzech bloków energetycznych rozpatrywanej elektrowni. W wersji tej nie było mechanizmów zapewniających zdobywanie wiedzy o obiekcie w czasie rzeczywistym. System SILO zdobywał wiedzę o obiekcie na podstawie pliku z danymi historycznymi. Wyniki pracy pierwszej wersji systemu SILO zostały przedstawione w [115, 116].

W lutym 2008 zakończono ponowne wdrożenie systemu SILO na bloku pierwszym i drugim. Podczas tego wdrożenia zainstalowano najnowszą wersję systemu SILO opisywaną w niniejszej rozprawie, oraz zwiększono ilość regulowanych wyjść obiektu.

### 11.2.1 Wyniki osiągnięte przez system SILO na bloku nr. 1

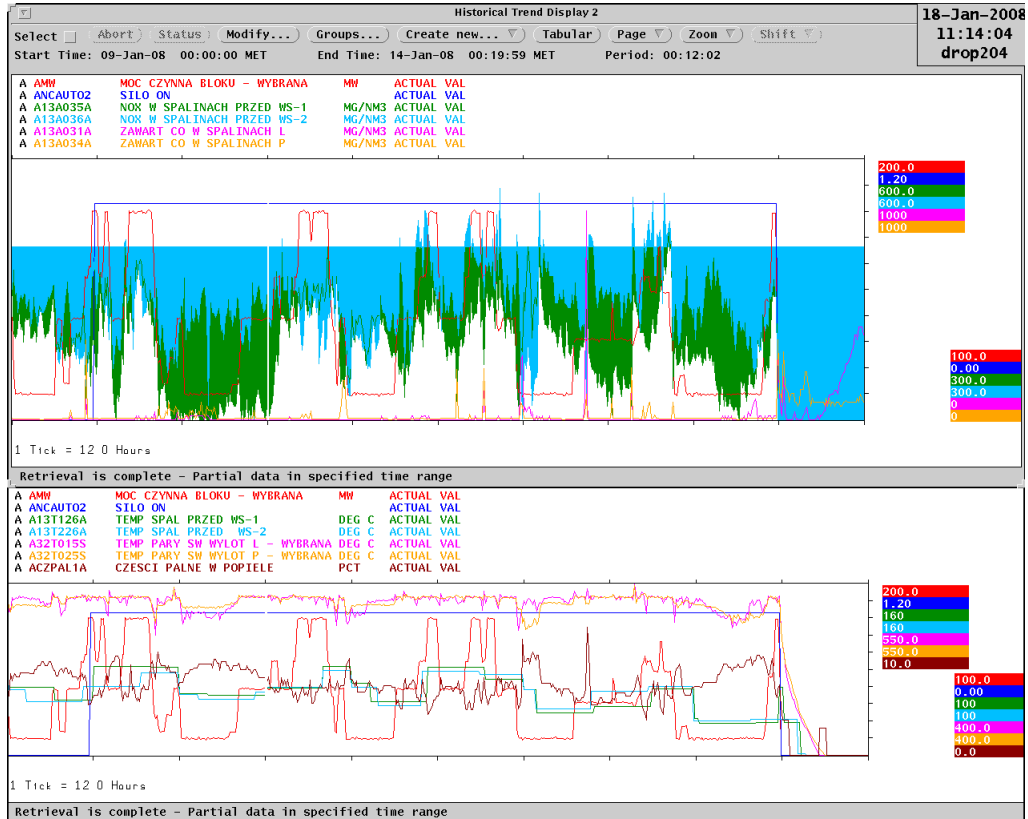
W poniższym rozdziale przedstawiono wyniki uzyskane przez system SILO na bloku nr. 1 rozpatrywanej elektrowni. Porównano wyniki pracy kotła będącego pod kontrolą systemu SILO, uzyskane po zakończeniu prac wdrożeniowych z wynikami pracy kotła bez nadzoru SILO, uzyskanymi bezpośrednio przed wdrożeniem systemu SILO.

Analizowano dane z okresu od 20.11.2007 do 17.01.2008. Nie uwzględniano czasu, w którym blok był wyłączony oraz danych z okresów, gdy występowały awarie czujników pomiarowych. W rozpatrywanym okresie obciążenie bloku zmieniało się od 106 MW do 203 MW. Średnie obciążenie bloku w tym czasie wyniosło 143.26 MW. Czas pracy optymalizatora SILO wyniósł 163.5 godzin, a łączny czas pracy kotła sterowanego przez operatorów 822 godzin.

W tabelach 11.3 - 11.7 oraz na rysunkach 11.24 - 11.26 porównano wyniki pracy kotła w sytuacji gdy system SILO sterował procesem i w sytuacji, gdy system SILO był wyłączony.

Tabela 11.2 Warunki pracy bloku nr. 1 podczas analizy.

	SILO OFF	SILO ON
Łączny czas trwania analizy [godz.]	822	163.5
Średnie obciążenie bloku [MW]	143.2	145.1
Zakres zmian mocy [MW]	106 - 195.3	107.8 - 203



Rysunek 11.23 Praca SILO przy różnych poziomach mocy (120 godzin).

Tabela 11.3 Porównanie wyników emisji  $\text{NO}_x$ .

	SILO OFF	SILO ON
Ilość przeanalizowanych średnich godzinowych	808	120
Ilość przekroczeń średnich godzinowych $\text{NO}_x$ [% czasu]	10.14	0
Przekroczenia śred. godz. $\text{NO}_x$ - moc 110 MW [% czasu]	8.91	0
Przekroczenia śred. godz. $\text{NO}_x$ - moc 180 MW [% czasu]	9.58	0
Średnia wartość średnich godzinowych $\text{NO}_x$ [ $\text{mg}/\text{Nm}^3$ ]	426.75	413.24
Średnia wartość $\text{NO}_x$ [ $\text{mg}/\text{Nm}^3$ ]	419.32	414.93
Średnia wartość $\text{NO}_x$ - moc 110 MW [ $\text{mg}/\text{Nm}^3$ ]	413.26	396.96
Średnia wartość $\text{NO}_x$ - moc 180 MW [ $\text{mg}/\text{Nm}^3$ ]	421.17	433.54

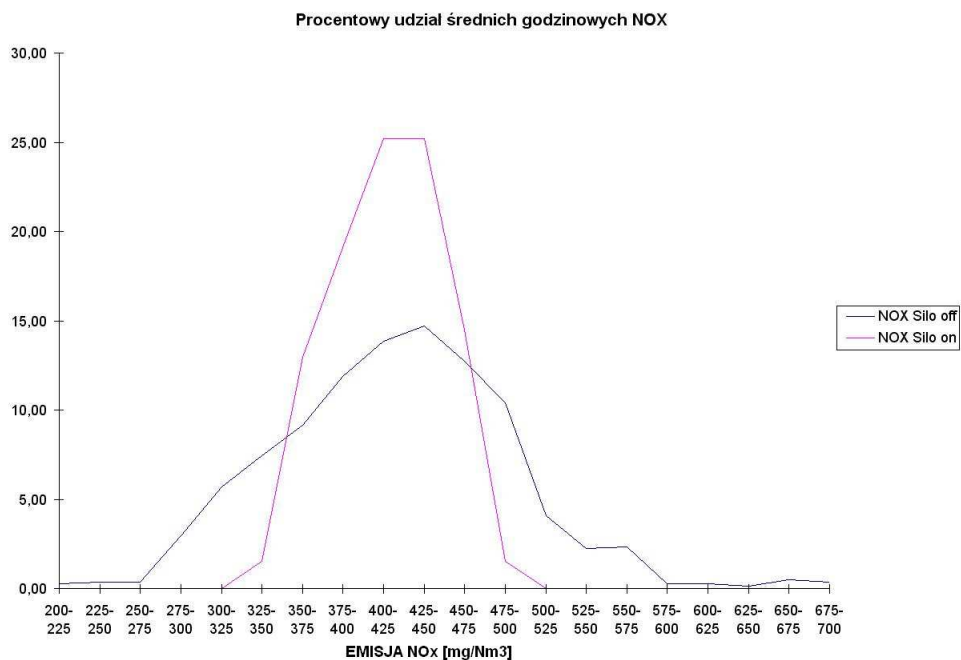
Rysunek 11.24 Procentowy udział średnich godzinowych  $\text{NO}_x$ .



Tabela 11.4 Porównanie wyników emisji CO.


	SILO OFF	SILO ON
Ilość przeanalizowanych średnich 5 minutowych	6372	1571
Ilość przekroczeń średnich 5 minutowych CO [% czasu]	1.15	0.19
Przekroczenia śred. 5 min. CO - moc 110 MW [% czasu]	0.77	0.17
Przekroczenia śred. 5 min. CO - moc 180 MW [% czasu]	0.66	0
Średnia wartość CO [mg/Nm <sup>3</sup> ]	15.46	8.34
Średnia wartość CO - moc 110 MW [mg/Nm <sup>3</sup> ]	14.19	9.01
Średnia wartość CO - moc 180 MW [mg/Nm <sup>3</sup> ]	17.56	4.97
Średnia wartość średnich 5 minutowych CO [mg/Nm <sup>3</sup> ]	14.05	8.33

Tabela 11.5 Porównanie zawartości części palnych.


	SILO OFF	SILO ON
Czas trwania analizy [godz]	700	163.5
Ilość przekroczeń dozwolonego poziomu [% czasu]	59	24.14
Średnia wartość części palnych w popiele [%]	5.16	3.92
Przekroczenia poziomu 5 % - moc 110 MW [% czasu]	76.43	39.27
Średnia wartość części palnych - moc 110 MW [%]	5.36	4.61
Przekroczenia poziomu 5 % - moc 180 MW [% czasu]	39.07	18.97
Średnia wartość części palnych - moc 180 MW [%]	4.92	3.21

Tabela 11.6 Porównanie temperatury pary świeżej.

	SILO OFF	SILO ON
Czas trwania analizy [godz]	822	163.5
Średnia wartość temperatury pary świeżej [°C]	532.24	536.58
Średnia wartość temp. pary świeżej - moc 180MW [°C]	537.74	538.77
Średnia wartość temp. pary świeżej - moc 110MW [°C]	526.56	530.73



Rysunek 11.25 Procentowy udział wartości temperatury pary świeżej przy mocy 110 MW.



Rysunek 11.26 Procentowy udział wartości temperatury pary świeżej przy mocy 180 MW.

Tabela 11.7 Porównanie temperatury spalin.

	SILO OFF	SILO ON
Czas trwania analizy [godz]	816	163.5
Średnia wartość temperatury spalin [°C]	117.76	120.54
Średnia wartość temp. spalin - moc 180 MW [°C]	123.30	119.89
Średnia wartość temp. spalin - moc 110 MW [°C]	114.02	122.55


Przedstawiona analiza wyników pokazuje, że:

- SILO w trybie on-line skutecznie steruje pracą bloku 1 w stanach ustalonych oraz przejściowych (zmiana mocy, przełączania młynów);
- Podczas sterowania kotłem przez SILO poziom średnich godzinowych emisji  $\text{NO}_x$  nie przekroczył ani razu dozwolonego poziomu ( $500 \text{ mg/Nm}^3$ ). W sytuacji, gdy SILO nie sterowało procesem spalania, średnia liczba przekroczeń wynosiła 10.14 %;
- Podczas sterowania kotłem przez SILO przekroczenia dozwolonego poziomu średnich 5-minutowych emisji CO ( $250 \text{ mg/Nm}^3$ ) stanowiły 0.19 % czasu pracy. Gdy SILO nie sterował kotłem ilość przekroczeń wynosiła 1.15 %;
- Temperatury pary świeżej zostały podniesione średnio o  $4.4 \text{ }^\circ\text{C}$ ;
- Optymalizacja za pomocą SILO spowodowała redukcję średniej zawartości części palnych w popiele z 5.16 % do 3.92 %, tym samym czas przekroczeń zawartości części palnych w popiele został zmniejszony z 59 % do 24.1 %;
- Temperatury spalin zostały utrzymane poniżej  $140 \text{ }^\circ\text{C}$ , zatem przez cały czas pracy SILO możliwe było prowadzenie procesu odsiarczania spalin dla bloku 1.


Na rys. 11.27 i 11.28 przedstawiono dwa niezależne załączenia systemu SILO, pokazujące wpływ tego systemu na wyniki pracy kotła energetycznego. Wyraźnie widać, że po załączeniu systemu SILO następuje zmniejszenie poziomu emisji  $\text{NO}_x$ .

### 11.2.2 Wyniki osiągnięte przez system SILO na bloku nr. 2

Analizie poddano dane z okresu od 01.12.2007 do 07.02.2008. Nie uwzględniano czasu, w którym blok był wyłączony oraz danych z okresów, gdy występowały awarie



Rysunek 11.27 Wpływ systemu SILO na pracę kotła na bloku 1 - test 1.



Rysunek 11.28 Wpływ systemu SILO na pracę kotła na bloku 1 - test 2.

czujników pomiarowych. Podczas rozpatrywanego przedziału czasowego obciążenie bloku numer 2 zmieniało się w zakresie od 115 MW do 206 MW. Średnie obciążenie bloku wynosiło 157.51 MW. Optymalizator SILO pracował przez 72 godziny, a łączny czas pracy kotła sterowanego przez operatorów wyniósł 987 godzin.

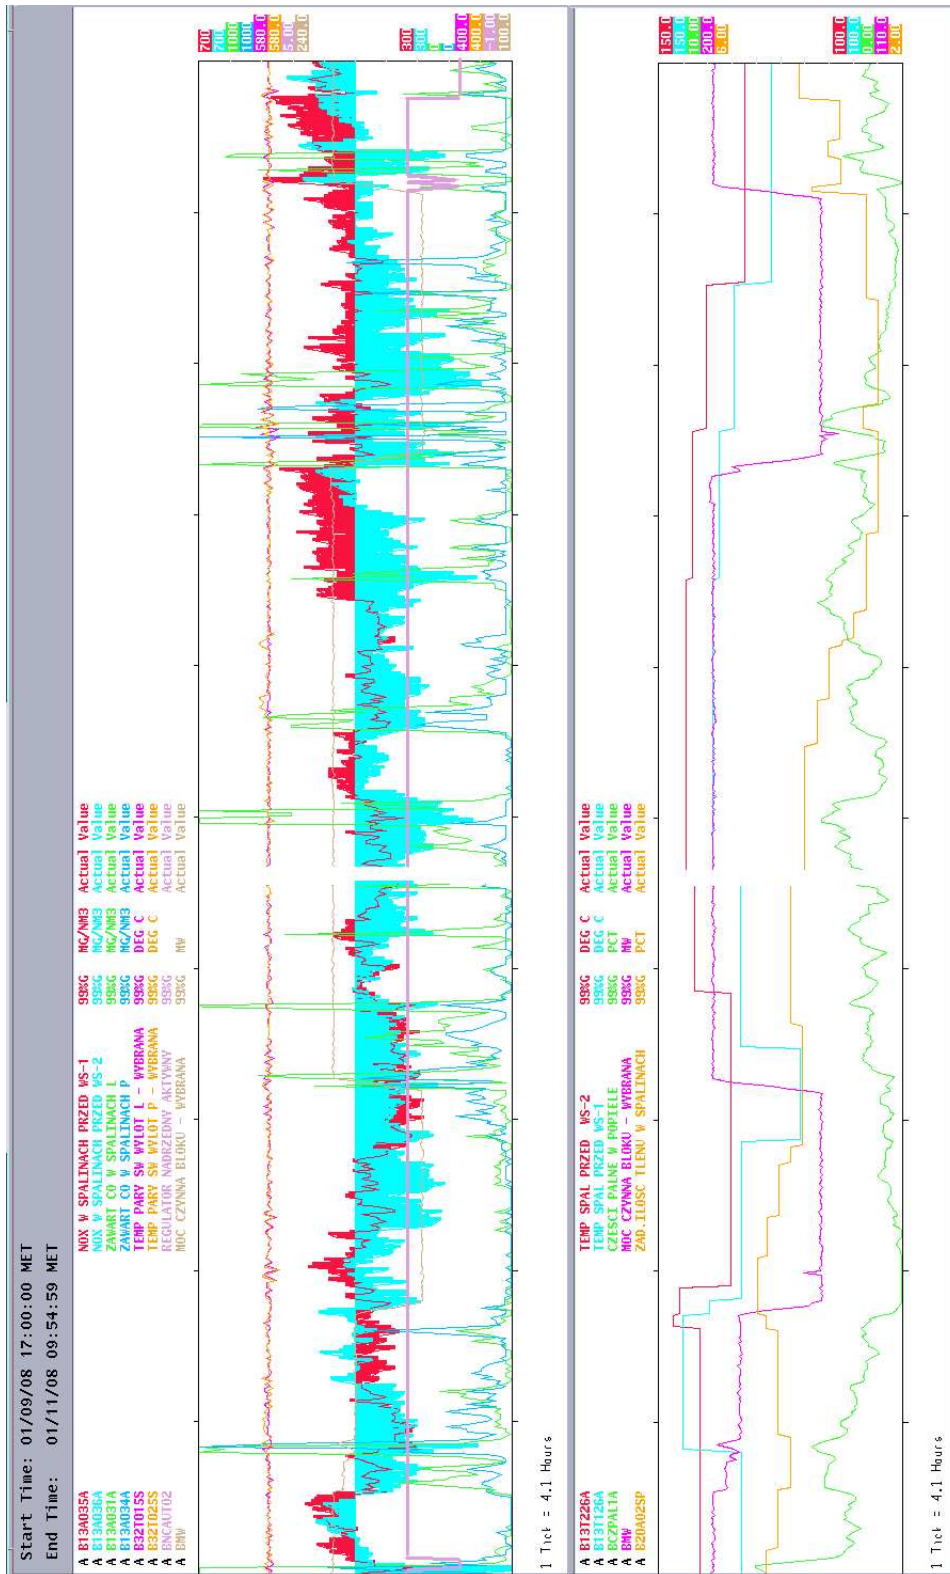
Tabela 11.8 Warunki pracy bloku nr. 2 podczas analizy.

	SILO OFF	SILO ON
Łączny czas trwania analizy [godz]	987	72
Średnie obciążenie bloku [MW]	157.85	159.45
Zakres zmian mocy [MW]	115 - 206.2	131.7 - 181.6

Na rysunku 11.29 przedstawiono 40 godzinny przebieg czasowy pracy kotła pod nadzorem SILO. W tabelach 11.9 - 11.12 oraz na rysunkach 11.30 - 11.33 porównano wyniki pracy kotła w sytuacji gdy system SILO sterował procesem i w sytuacji, gdy system SILO był wyłączony.

Tabela 11.9 Porównanie wyników emisji NO<sub>x</sub> na bloku 2.

	SILO OFF	SILO ON
Ilość przeanalizowanych średnich godzinowych	987	72
Ilość przekroczeń średnich godzinowych NO <sub>x</sub> [% czasu]	60.69	9.72
Przekroczenia śred. godz. NO <sub>x</sub> - moc 140 MW [% czasu]	71.89	4
Przekroczenia śred. godz. NO <sub>x</sub> - moc 160 MW [% czasu]	19.6	0
Przekroczenia śred. godz. NO <sub>x</sub> - moc 180 MW [% czasu]	66.15	21.05
Średnia wartość średnich godzinowych NO <sub>x</sub> [mg/Nm <sup>3</sup> ]	522.57	441.92
Średnia wartość NO <sub>x</sub> [mg/Nm <sup>3</sup> ]	522.72	441.91
Średnia wartość NO <sub>x</sub> - moc 140 MW [mg/Nm <sup>3</sup> ]	538.95	451.27
Średnia wartość NO <sub>x</sub> - moc 160 MW [mg/Nm <sup>3</sup> ]	440.16	391.52
Średnia wartość NO <sub>x</sub> - moc 180 MW [mg/Nm <sup>3</sup> ]	533.77	481.33



Rysunek 11.29 Przebieg czasowy procesu spalania pod nadzorem SIŁO na bloku 2 (40 godzin).


Rysunek 11.30 Procentowy udział średnich godzinowych NO<sub>x</sub>.

Tabela 11.10 Porównanie wyników emisji CO na bloku 2.

	SILO OFF	SILO ON
Ilość przeanalizowanych średnich 5 minutowych	11854	864
Ilość przekroczeń średnich 5 minutowych CO [% czasu]	3.93	7.63
Przekroczenia śred. 5 min. CO - moc 140 MW [% czasu]	1.08	6.56
Przekroczenia śred. 5 min. CO - moc 160 MW [% czasu]	4.5	4.15
Przekroczenia śred. 5 min. CO - moc 180 MW [% czasu]	8.89	12.98
Średnia wartość CO [mg/Nm <sup>3</sup> ]	41.9	60.49
Średnia wartość CO - moc 140 MW [mg/Nm <sup>3</sup> ]	17.68	51.49
Średnia wartość CO - moc 160 MW [mg/Nm <sup>3</sup> ]	34.67	28.27
Średnia wartość CO - moc 180 MW [mg/Nm <sup>3</sup> ]	75.63	90.9



Rysunek 11.31 *Piki CO* w przypadku sterowania przez operatora.Rysunek 11.32 *Piki CO* w przypadku regulacji SIŁO.



Tabela 11.11 Porównanie zawartości części palnych w popiele na bloku 2.

	SILO OFF	SILO ON
Czas trwania analizy [godz]	987.86	72
Ilość przekroczeń dozwolonego poziomu [% czasu]	15.76	6.15
Średnia zawartość części palnych w popiele [%]	3.14	2.2
Przekroczenia poziomu 5 % - moc 140 MW [% czasu]	17.71	12.34
Średnia wartość części palnych - moc 140 MW [%]	3.34	2.23
Przekroczenia poziomu 5 % - moc 160 MW [% czasu]	2.98	5.67
Średnia wartość części palnych - moc 160 MW [%]	1.4	2.58
Przekroczenia poziomu 5 % - moc 180 MW [% czasu]	19.21	0
Średnia wartość części palnych - moc 180 MW [%]	3.52	1.73

Tabela 11.12 Porównanie temperatury pary świeżej na bloku 2.

	SILO OFF	SILO ON
Czas trwania analizy [godz.]	987.86	72
Średnia wartość temperatury pary świeżej [°C]	539.03	539.32
Średnia wartość temp. pary świeżej - moc 140MW [°C]	538.65	539.06
Średnia wartość temp. pary świeżej - moc 160MW [°C]	538.94	538.72
Średnia wartość temp. pary świeżej - moc 180MW [°C]	539.59	540.11

Przedstawiona analiza wyników pokazuje, że:


- SILO w trybie on-line skutecznie steruje pracą bloku nr. 2 w stanach ustalonych oraz przejściowych (zmiana mocy, przełączania młynów);
- SILO podczas swojej pracy ograniczył ilość przekroczeń średnich godzinowych  $\text{NO}_x$  z 60.69 % (SILO wyłączone) do poziomu 9.72 % (SILO włączone) co stanowi znaczną poprawę;
- Gdy SILO sterował procesem ilość przekroczeń emisji CO wzrosła z poziomu 3.93 % (SILO wyłączone) do poziomu 7.63 % (SILO włączone). Podczas zmiany konfiguracji młynów węglowych pojawiają się gwałtowne *skoki* sygnału CO niezależnie od tego czy kotłem steruje SILO czy operator. Przedstawione zachowanie procesu znacznie utrudnia pracę optymalizatora SILO (patrz rys. 11.31 i 11.32);
- Temperatury pary świeżej zostały podwyższone średnio o 0.3 °C;
- Średnia zawartość części palnych w popiele zmalała z 3.14 % (SILO wyłączone) do 2.2 % (SILO włączone) oraz czas przekroczeń został zredukowany z 15.76 % (SILO wyłączone) do 6.15 % (SILO włączone);
- Nie dokonano analizy temperatur spalin ze względu na brak pomiarów temperatur spalin w Serwerze Danych Historycznych. Podczas obserwacji pracy SILO na obiekcie nie zaobserwowano przekroczeń temperatur spalin.

Na rys. 11.33 przedstawiono załączenie systemu SILO, pokazujące wpływ tego systemu na wyniki pracy kotła energetycznego. Wyraźnie widać, że po załączeniu systemu SILO następuje zmniejszenie poziomu emisji  $\text{NO}_x$ .

### 11.3 Ogólne wnioski z przeprowadzonych wdrożeń

Analizując pracę systemu SILO w obu przedstawionych w niniejszym rozdziale elektrowniach, można sformułować pewne wnioski natury ogólnej. Pomimo występowania silnych oscylacji i szumów pomiarowych sygnałów reprezentujących sterowania, zakłócenia i wyjścia obiektu:

- system SILO jest w stanie prowadzić bieżącą optymalizację punktu pracy procesu spalania w kotle energetycznym;



Rysunek 11.33 Wpływ systemu SILO na pracę kotła - blok nr. 2.

- system SILO jest w stanie zdobywać wiedzę o procesie i adaptować się do zmieniających się warunków pracy;
- dzięki wdrożeniu systemu SILO w warstwie nadrzędnej w stosunku do warstwy regulacji podstawowej, nie ma potrzeby wyłączania systemu SILO w trakcie zmiany obciążeń kotła i zmiany konfiguracji pracujących młynów;
- średni czas wdrożenia systemu SILO, nie uwzględniający wykonania grafik operatorskich i zmian w układach regulacji podstawowej, wynosi ok. 12 dni roboczych.

## Rozdział 12 Podsumowanie

W niniejszej rozprawie przedstawiono system SILO służący do bieżącej optymalizacji punktu pracy procesów technologicznych. Rozwiązanie to ma zastosowanie dla procesów, w których zmiana zakłóceń następuje szybko, ale rzadko lub zakłócenia zmieniają się w sposób ciągły, ale prędkość tych zmian jest dużo wolniejsza od dynamiki obiektu regulowanego. Algorytmy zaimplementowane w systemie SILO inspirowane są działaniem układu odpornościowego organizmów żywych. W rozprawie przedstawiono mechanizmy układu odpornościowego. Omówiono zastosowanie Sztucznych Systemów Immunologicznych w dziedzinie regulacji. Przedstawiono stworzoną przez autora strukturę rozwiązania SILO i pokazano jej podobieństwa do struktury układu odpornościowego organizmów żywych. W systemie SILO patogeny reprezentują zakłócenia (mieralne i niemieralne) oddziałujące na proces. Przeciwciała to przyrosty sygnałów sterowań obliczane przez moduł optymalizacji. Optymalny wektor sterowań obliczany jest na podstawie wiedzy zgromadzonej w pamięci immunologicznej składającej się z limfocytów typu B. Każdy limfocyt typu B to podstawowy kwant wiedzy o obiekcie regulacji. Limfocyty typu B przechowują wiedzę na temat statycznych odpowiedzi obiektu na zmianę sterowania, zmierzonych w różnych punktach pracy. Omawiając działanie modułu optymalizacji i modułu uczenia, zwrócono uwagę na wykorzystanie charakterystycznej cechy układu immunologicznego jaką jest umiejętność nauki i adaptacji do zmieniających się warunków pracy. Należy w tym miejscu podkreślić, że podobnie jak w przypadku innych metod czerpiących inspiracje z obserwacji mechanizmów biologicznych (np: Sztuczne Sieci Neuronowe, Algorytmy Ewolucyjne, Algorytmy Mrówkowe i.t.p.), analiza mechanizmów występujących w świecie żywych organizmów jest jedynie punktem startowym rozważań, które przyczyniły się do powstania systemu SILO. Mechanizmy i struktura układu odpornościowego stanowiły jedynie inspirację do stworzenia opisywanego w niniejszej rozprawie rozwiązania.

W systemie SILO zadanie bieżącej optymalizacji punktu pracy procesu technologicznego i zadanie zdobywania wiedzy realizowane są jednocześnie przez dwa niezależne moduły. Pozwala to na optymalne wykorzystanie czasu pracy systemu SILO. Moduł uczenia na bieżąco analizuje aktualne i historyczne wartości punktów procesowych i na ich podstawie buduje podstawowe jednostki wiedzy o procesie reprezentowane przez limfocyty typu B. Skuteczność zaprojektowanego algorytmu zdobywania wiedzy została potwierdzona podczas rzeczywistych wdrożeń systemu SILO.

Moduł optymalizacji wykorzystuje wiedzę zawartą w limfocytach do budowy matematycznego modelu procesu. Model ten wykorzystywany jest w zadaniu optymalizacji do minimalizacji wartości wskaźnika jakości. Zaproponowana przez autora strategia wyznaczania optymalnego wektora sterowań dostosowana jest zarówno do ilości jak również i jakości wiedzy na temat procesu zgromadzonej w pamięci immunologicznej. Moduł optymalizacji pracuje w jednej z trzech warstw reprezentujących odmienne algorytmy poszukiwania najlepszego rozwiązania. Warstwa optymalizacji stochastycznej wykonywana jest gdy system SILO nie posiada wystarczającej ilości informacji na temat obiektu regulacji, lub gdy wiedza ta nie jest wystarczająco dokładna. Algorytm zaimplementowany w tej warstwie realizuje stochastyczną eksplorację przestrzeni rozwiązań. Stosując analogię do układu odpornościowego organizmów żywych, warstwa ta związana jest z pierwotną odpowiedzią układu odpornościowego. Warstwa optymalizacji na modelu mieszanym wykonywana jest, gdy system SILO posiada wiedzę o procesie w okolicy aktualnego punktu pracy. Realizowana w tej warstwie eksploatacja przestrzeni rozwiązań odpowiada wtórnej reakcji układu odpornościowego. Pośrednią warstwą jest warstwa optymalizacji na modelu globalnym. W warstwie tej system SILO nie dysponuje informacją o zachowaniu obiektu w okolicy aktualnego punktu pracy, dostępna jest jednak wiedza o zachowaniu obiektu w innych punktach pracy. Na podstawie tej wiedzy budowany jest matematyczny model procesu. Przedstawiony w niniejszej rozprawie algorytm przełączania między warstwami jest kluczowym mechanizmem systemu SILO i w głównej mierze decyduje on o efektywności prezentowanego rozwiązania. Jest on odpowiedzialny za odpowiedni rozdział zasobów czasowych przeznaczonych na eksplorację i eksploatację przestrzeni rozwiązań.

Właściwości systemu SILO zostały porównane z właściwościami podejścia bazującego na metodach regulacji predykcyjnej. Zwrócono uwagę, że dla pewnej klasy procesów, SILO stanowi tanią alternatywę dla regulatorów MPC. Wynika to z tego, że koszt wdrożenia przedstawionego w niniejszej rozprawie rozwiązania jest istotnie

niższy. Związane jest to z brakiem konieczności przeprowadzania czasochłonnych eksperymentów identyfikacyjnych obiektu regulacji przez inżynierów wdrażających regulator i brakiem konieczności budowy dynamicznego modelu procesu technologicznego. Ponadto brak konieczności przeprowadzania eksperymentów na pracującym obiekcie, zgodnie z założonym planem testów identyfikacyjnych, skutkuje tym, że nie ma potrzeby modyfikowania harmonogramu produkcji zakładu przemysłowego i zakład przemysłowy nie musi ponosić negatywnych skutków ekonomicznych takich modyfikacji. W systemie SILO, każda zmiana sterowania jest potencjalnym eksperymentem identyfikacyjnym. W początkowej fazie działania systemu SILO, gdy baza wiedzy jest relatywnie mała, sterowania wyznaczane są w oparciu o heurystykę zaimplementowaną w warstwie optymalizacji stochastycznej. Głównym zadaniem tej warstwy jest zdobycie wiedzy o obiekcie regulacji. Eksperymenty identyfikacyjne są wykonywane automatycznie, a heurystyka odpowiedzialna za wykonywanie tych eksperymentów pozwala na zmniejszenie wartości wskaźnika jakości w długim horyzoncie czasowym. Przedstawiony w niniejszej rozprawie mechanizm adaptacji umożliwia uwzględnienie ciągłych zmian charakterystyk optymalizowanego procesu. Zmiany te, rozpatrywane na horyzoncie miesięcy i lat, wynikają ze zużycia i awarii urządzeń wykonawczych, zmiany sposobu prowadzenia procesu, przebudowy instalacji przemysłowej, istotnych zmian właściwości chemicznych używanych składników oraz zmiany warunków zewnętrznych. Wykorzystanie tego mechanizmu adaptacji powoduje, że w systemie SILO konieczność ponownego strojenia modelu, wynikająca ze zmiany charakterystyk obiektu jest istotnie ograniczona w porównaniu do regulatorów MPC.

W rozprawie przedstawiono wdrożenie systemu SILO do optymalizacji procesu spalania w kotle energetycznym. Przedstawiono budowę kotła energetycznego i omówiono proces spalania pod kątem jego optymalizacji. W rozdziale 11 przedstawiono wyniki uzyskane przez system SILO na dwóch blokach energetycznych jednej z amerykańskich elektrowni i dwóch blokach energetycznych jednej z polskich elektrowni. Analiza uzyskanych wyników pokazuje, że prezentowane rozwiązanie jest w stanie w czasie rzeczywistym skutecznie realizować założone cele optymalizacji w warunkach rzeczywistych.

Za wartości merytoryczne pracy uważa się:

- wykorzystanie mechanizmów, inspirowanych działaniem układu odpornościowego organizmów żywych, do opracowania koncepcji bieżącej optymalizacji punktu pracy procesu technologicznego;

- opracowanie warstwowego algorytmu optymalizacji, dostosowującego swoje działanie nie tylko do aktualnego stanu procesu, ale także do wiedzy systemu SILO o obiekcie regulacji;
- opracowanie metody zdobywania wiedzy o procesie i wykorzystania tej wiedzy do tworzenia modeli matematycznych obiektu regulacji;
- porównanie właściwości systemu SILO z algorytmami regulacji predykcyjnej z przesuwającym horyzontem;
- analizę wdrożeń przedstawionego rozwiązania na czterech rzeczywistych blokach energetycznych.

Przedstawione w niniejszej rozprawie rozwiązanie stanowi przedmiot wniosków patentowych złożonych w Polsce, USA, Indiach i Chinach. Wyróżnienia związane z systemem SILO zostały wymienione w dodatku C. Wdrożenia przeprowadzone w polskich i amerykańskich elektrowniach potwierdzają skuteczność prezentowanego rozwiązania. Lista wszystkich wdrożeń systemu SILO znajduje się w dodatku B.

## Dodatek A Wkład osób trzecich w rozwój systemu SILO

W załączniku przedstawiono wkład osób trzecich w rozwój systemu SILO:

- Dr Konrad Świrski – Jako prezes firmy Transition Technologies S.A. postanowił finansować badania nad prezentowanym rozwiązaniem oraz wspierać finansowo udział autora w konferencjach zagranicznych. Pan dr Konrad Świrski zadbał również o umożliwienie przeprowadzenia wdrożenia systemu SILO w omawianych w rozdziale 11 elektrowniach;
- Dr Michał Warchoła – Wkładem dr Michała Warchoła w rozwój systemu SILO była pomoc przy tworzeniu rozwiązań informatycznych zapewniających współdziałanie systemu SILO z systemami DCS. Ponadto dr Michał Warchoła pomógł autorowi przy zdefiniowaniu zadania LQ przedstawionego w rozdziale 8;
- Mgr inż. Tomasz Chomiak – Wkładem mgr inż. Tomasza Chomiaka była pomoc świadczona autorowi podczas procesu wdrożenia SILO w jednej z polskich elektrowni. Pan mgr inż. Tomasz Chomiak dzielił się z autorem wiedzą na temat procesu spalania zachodzącego w kotle energetycznym i wiedzą dotyczącą konfiguracji różnych systemów DCS;
- Mgr Walerian Sokołowski – Wkładem mgr Waleriana Sokołowskiego w rozwój systemu SILO była pomoc przy tworzeniu kodu źródłowego systemu SILO. Około 40 % kodu źródłowego systemu SILO było napisane przez mgr Waleriana Sokołowskiego, na podstawie przygotowanego przez autora projektu.



## Dodatek B Zakończony i planowane wdrożenia systemu SILO

W momencie złożenia niniejszej rozprawy do druku (październik 2008), system SILO realizował nadrzędną regulację procesu spalania w elektrowniach:

- Ostrołęka – blok 1 (200 MW),
- Ostrołęka – blok 2 (200 MW),
- Ostrołęka – blok 3 (200 MW),
- Połaniec – blok 4 (200 MW),
- Newton (USA) – blok 1 (600 MW),
- Newton (USA) – blok 2 (600 MW),
- Danscamer (USA) – blok 4 (250 MW),
- Duke Allen (USA) – blok 2 (185 MW),
- Nearman (USA) – blok 1 (185 MW).

W najbliższym czasie planowe są następujące wdrożenia systemu SILO:

- optymalizacja procesu spalania w kotle energetycznym – elektrownia TPC Taichung (Tajwan), blok 8 (550 MW);
- optymalizacja procesu spalania w kotle energetycznym – elektrownia Połaniec, blok 1 (200 MW);
- optymalizacja procesu odsiarczania spalin – elektrownia Połaniec;
- optymalizacja procesu mieszania (ang. blending) komponentów w celu uzyskania paliw o pożądanym właściwościach – Rafineria Lotos.

## Dodatek C Otrzymane wyróżnienia

System SILO uzyskał następujące wyróżnienia:

- Srebrny medal na Międzynarodowych Targach Wynalazczości i Nowych Technologii – INNOVA 2006 w Brukseli;
- Dyplom Ministra Nauki i Szkolnictwa Wyższego na wystawie polskich wynalazków, Warszawa 2007;
- Produkt Roku 2007 w kategorii Zaawansowane Przetwarzanie i Regulacja – nagroda przyznana przez czasopismo Control Engineering.

# Bibliografia

- [1] I. Alaya, C. Solnon, and K. Ghedira. Ant colony optimization for multi-objective optimization problems. In *Proc. of the 19th IEEE International Conference on Tools with Artificial Intelligence*, Patras, Grecja, październik 2007.
- [2] J. Arabas. *Wykłady z Algorytmów Ewolucyjnych*. WNT, Warszawa, 2001.
- [3] J. Arabas, L. Białobrzęski, P.D. Domański, and K. Świrski. Advanced boiler control. In *Proc. of MMAR'98*, Miedzyzdroje, Polska, 1998.
- [4] J. Arabas, L. Białobrzęski, T. Chomiak, P. D. Domański, K. Świrski, and R. Neelakantan. Pulverized coal fired boiler optimization and  $NO_x$  control using neural networks and fuzzy logic. In *Proc. of AspenWorld'97*, Boston, Massachusetts, październik 1997.
- [5] K. J. Astrom and T. Hagglund. *PID Control – Theory, Design and Tuning*. Instrument Society of America, 1995.
- [6] R. Babuska, J.M. Sousa, and H.B. Verbruggen. Predictive control of non-linear systems based on fuzzy and neural models. In *Proceedings of the 5th European Control Conference*, 1999.
- [7] T. Back. *Evolutionary Algorithms in theory and practice*. Oxford University Press, 1996.
- [8] G. A. Bakare, G. Krost, G. K. Venayagamoorthy, and U.O. Aliyu. Comparative application of differential evolution and particle swarm techniques to reactive power and voltage control. In *14th International Conference on Intelligent System Applications to Power Systems*, Kaohsiung, Taiwan, 2007.

- [9] J. Balthrop, S. Forrest, and M. Glickman. Revisiting lisy: Parameters and normal behavior. In *Proceedings of the Congress on Evolutionary Computation*, page 1045–1050, 2002.
- [10] A. Bemporad and E. Mosca. Fulfilling hard constraints in uncertain linear systems by reference managing. *Automatica* 34(4), pages 451–461, 1998.
- [11] T.L. Blevins, G.K. McMillan, W.K. Wojsznis, and M.W. Brown. *Advanced Control Unleashed*. ISA, 2003.
- [12] D. Bradley and A. Tyrrell. Immunotronics: Hardware fault tolerance inspired by the immune system. In *Proceedings of the 3rd International conference on Evolvable Systems (ICES2000)*, pages 11–20. Springer-Verlag, 2000.
- [13] E. F. Camacho and C. Bordons. *Model Predictive Control*. Springer Verlag, London, 1999.
- [14] M. Canale and M. Milanese. *Robust Design of Predictive Controllers in Presence of Unmodeled Dynamics*. Politecnico di Torino, 2001.
- [15] Y. Cao and D. Dasgupta. An immunogenetic approach in chemical spectrum recognition. In *Advances in Evolutionary Computing*, chapter 36. Springer-Verlag, 2003.
- [16] L. N. De Castro and J. I. Timmis. Artificial immune systems as a novel soft computing paradigm. *Soft Computing*, 7(8):526–544, 2003.
- [17] L. N. De Castro and F.J. Von Zuben. Artificial immune systems: Part I – basic theory and applications. Technical Report RT DCA 01/99, Department of Computer Engineering and Industrial Automation, School of Electrical and Computer Engineering, State University of Campinas, Campinas, SP, Brazil, grudzień 1999.
- [18] L. N. De Castro and F.J. Von Zuben. Artificial immune systems: Part II – a survey of applications. Technical Report RT DCA 02/00, Department of Computer Engineering and Industrial Automation, School of Electrical and Computer Engineering, State University of Campinas, Campinas, SP, Brazil, luty 2000. <ftp://ftp.dca.fee.unicamp.br/pub/docs/techrep/2000/DCA00-002.pdf>.

- 
- [19] P.C. Chandrasekharan. *Robust Control of Linear Dynamical Systems*. Academic Press, 1996.
- [20] W. Chen, J. Zhou, and H. Wei. Compensatory controller based on artificial immune system. In *Proceedings of the 2006 IEEE International Conference on Mechatronics and Automation*, 2006.
- [21] D. W. Clarke, C. Mohtadi, and P. S. Tuffs. Generalised predictive control – parts I and II. *Automatica*, 23:137–160, 1987.
- [22] C. R. Cutler and B. L. Ramaker. Dynamic matrix control – a computer control algorithm. In *Proc. Joint Automatic Control Conference*, San Francisco, 1980.
- [23] D. Dasgupta. Immune-based intrusion detection system: A general framework. In *Proceedings of the 22nd National Information Systems Security Conference (NISSC)*, 1999.
- [24] D. Dasgupta. Advances in artificial immune systems. *IEEE Computational Intelligence Magazine*, 23:40–49, listopad 2006.
- [25] D. Dasgupta, K. Krishnakumar, D. Wong, and M. Berry. Negative selection algorithm for aircraft fault detection. In *Proceedings of the Third International Conference, ICARIS 2004 on Artificial Immune Systems*, Catania, Włochy, 2004.
- [26] M. Dąbrowski. *Układ odpornościowy – twój osobisty doktor*. Sanmedia, Warszawa, 1994.
- [27] L. Desborough and R. Miller. Increasing customer value of industrial control performance monitoring – Honeywell’s experience. In *Proc. of 2004 American Control Conference*, Boston, USA, czerwiec 2004.
- [28] P. Domański, K. Świrski, and J. Lewandowski. Wykorzystanie sieci neuronowych i optymalizacji w energetyce: porównanie doświadczeń Polska i USA. In *Prace IMiUE Politechniki Śląskiej, IX Konferencja Kotłowa*, pages 143–164, 2002.
- [29] P. Domański, K. Świrski, and J.J. Williams. Application of advanced control technologies to the emission control and optimization. In *Proc. of Conference on Power Plant Emission Control and Monitoring Technologies*, London, 2000.

- [30] M. Dorigo and T. Stutzle. *Ant Colony Optimization*. MIT Press, 2004.
- [31] D. Driankov, H. Hallendoorn, and M. Reinfrank. *Wprowadzenie do sterowania rozmytego*. Wydawnictwo Naukowo-Techniczne, Warszawa, 1996.
- [32] S. G. Dukelew. *The Control of Boilers – II edition*. ISA, USA, 1991.
- [33] A.A. Feldbaum. *Podstawy teorii optymalnych układów sterowania*. PWN, Warsaw, 1968.
- [34] T. Fukuda, K. Mori, and M. Tsukiama. Parallel search for multi-modal function optimization with diversity and learning of immune algorithm. In Dipankar Dasgupta, editor, *Artificial Immune Systems and Their Applications*, pages 210–220. Springer, grudzień 1998.
- [35] C.E. Garcia and A.M. Morshedi. Quadratic programming solution of dynamic matrix control (qdmc). *Chemical Engineering Communications*, 46:73 – 87, 1986.
- [36] G. Gattu and E. Zafiriou. Nonlinear quadratic dynamic matrix control with state estimation. *Ind. Eng. Chem.*, 1992.
- [37] G. Góral and J. Szymczak. Rozmyte regulatory spalania. In *II konferencja naukowo-techniczna – Kontrola, Sterowanie i Automatyzacja Procesu Spalania w Kociołach Energetycznych*, Szczyrk, 2007.
- [38] J. Górecki, A. Andruszkiewicz, and K. Kubas. Optymalizacja pracy bloku energetycznego poprzez dostosowywanie strumienia wody chłodzącej kondensatory do jego aktualnej mocy. In *VII Konferencja – Problemy badawcze energetyki cieplnej*, Warszawa, 2005.
- [39] S. Haykin. *Neural Networks – A Comprehensive Foundation*. Prentice Hall, Englewood Cliffs, 1999.
- [40] M.A. Henson. Nonlinear model predictive control: current status and future directions. *Computers and Chemical Engineering*, 1998.
- [41] S.A. Hofmeyr and S. Forrest. Architecture for an artificial immune system. *Evolutionary Computation*, 8:443–473, 2000.

- 
- [42] D. Horla. Optymalizacja wypukła w zastosowaniu do syntezy adaptacyjnego regulatora predykcyjnego z niejawnym układem anti-windup. In *KKAXV*, pages 279–284, Warszawa, 2005.
- [43] N.J. Jerne. Idiotypic networks and other preconceived ideas. *Immunological Review*, 1984.
- [44] Z. Ji and D. Dasgupta. Applicability issues of the real-valued negative selection algorithms. In *Genetic and Evolutionary Computation Conference (GECCO)*, page 111 – 118, 2006.
- [45] A.H. Jones, N. Ajlouni, Ying-Chin Lin, S.B. Kenway, and M. Uzam. Genetic design of robust PID plus feedforward controllers. In *Proc. of IEEE Conference on Emerging Technologies and Factory Automation EFTA '96*, Kauai, USA, 1996.
- [46] L. Jung and T. Soderstrom. *Theory and Practice of Recursive Identification*. MIT Press, Cambridge, Massachusetts, 1983.
- [47] C. Karr, K. Nishita, and K. Graham. Adaptive aircraft flight control simulation based on an artificial immune system. *Applied Intelligence*, 23:295–308, grudzień 2005.
- [48] E. C. Karrigan. *Robust Constraints Satisfaction: Invariant Sets and Prediction*. University of Cambridge, 2000.
- [49] D. E. Kassmann, T. A Badgwell, and R. B. Hawkins. Robust steady-state target calculation for model predictive control. *AIChE Journal*, pages 1007–1024, 2000.
- [50] J. Kennedy and R. C. Eberhart. *Swarm Intelligence*. Morgan Kaufmann, 2001.
- [51] D. H. Kim, J. H. Jo, and H. Lee. Robust power plant control using clonal selection of immune algorithm based multiobjective. In *Proceedings of the Fourth International Conference on Hybrid Intelligent Systems (HIS'04)*, 2004.
- [52] H. S. Kim, J. M. Lee, T. R. Park, and W. H. Kwon. Design of networks for distributed digital control systems in nuclear power plants. In *Proceedings of 2000 International Topical Meeting on NPIC, and HMIT*, pages 629–633, 2000.

- [53] J. Kim and P. Bentley. Toward an artificial immune system for network intrusion detection: An investigation of dynamic clonal selection. In *Toward an artificial immune system for network intrusion detection: An investigation of dynamic clonal selection*, pages 1244—1252, Honolulu, Hawaii, 2002.
- [54] M.V. Kothare, V. Venkataramanan, and M. Morari. *Robust Constrained Model Predictive Control using Linear Matrix Inequalities*. California Institute of Technology, 1996.
- [55] K. Krishnakumar and J. Neidhoefer. An immune system framework for integrating computational intelligence paradigms with applications to adaptive control. In M. Palaniswami, Y. Attikiouzel, R. J. II Marks, D. Fogel, and T. Fukuda, editors, *Computational Intelligence: A Dynamic System Perspective*, pages 32–45. IEEE Press, Piscataway, NJ, październik 1995.
- [56] K. Krishnakumar and J. Neidhoefer. Immunized adaptive critics for level 2 intelligent control. In *1997 IEEE International Conference on Systems, Man, and Cybernetics*, volume 1, pages 856–861, Orlando, FL, październik 1997. IEEE.
- [57] K. Krishnakumar and J. Neidhoefer. Immunized neurocontrol. *Expert Systems with Applications*, 13(3):201–214, październik 1997.
- [58] K. Krishnakumar and J. Neidhoefer. Immunized adaptive critic for an autonomous aircraft control application. In *Artificial Immune Systems and Their Applications*, pages 221–240. Springer-Verlag, 1999.
- [59] A. Królikowski. *Sterowanie adaptacyjne z ograniczeniami sygnału sterującego*. WPP, Poznań, 2004.
- [60] D. Laudyn, M. Pawlik, and F. Strzelczyk. *Elektrownie*. Wydawnictwo Naukowo-Techniczne, Warszawa, 2000.
- [61] M. Lawrynczuk and P. Tatjewski. A computationally efficient nonlinear predictive control algorithm based on neural models. In *Proceedings of the 8th IEEE Conf. on Methods and Models in Automation and Robotics*, 2002.
- [62] J. Lofberg. *Minima approaches to robust model predictive control*. rozprawa doktorska. Linköping University, 2003.



- 
- [63] Peter M. Lydyard, A. Whelan, and Michael W. Fanger. *Instant Notes in Immunology*. Instant Notes Series. BIOS Scientific Publishers Limited, 2000.
- [64] J. M. Maciejowski. *Predictive Control*. Prentice Hall, Harlow, England, 2002.
- [65] K. Malinowski. *Analiza i projektowanie sterowania dla złożonych systemów: Zadania i struktury sterowania*. IAIIS PW, 1998.
- [66] P. Marquis and J.P. Broustail. SMOC, a bridge between state space and model predictive controllers: Application to the automation of a hydrotreating unit. In *Proceedings of the 1988 IFAC Workshop On Model Based Process Control*, 1988.
- [67] P. Marusak. *Regulacja predykcyjna obiektów nieliniowych z zastosowaniem technik DMC i modelowania rozmytego*. rozprawa doktorska. Politechnika Warszawska, Warszawa, 2002.
- [68] P. Marusak and P. Tatjewski. Fuzzy dynamic matrix control algorithms for non-linear plants. In *Proceedings of the 6th Int. Conference on Methods and Models in Automation and Robotics*, 2000.
- [69] D. Q. Mayne. Nonlinear model predictive control: An assessment. In *Fifth International Conference on Chemical Process Control*, pages 217 – 131, 1997.
- [70] E. S. Meadows and J. B. Rawling. *Model Predictive Control*, chapter 5, pages 233 – 310. Prentice Hall, 1997.
- [71] D. Megias, J. Serrano, and C. de Prada. *Min-Max Constrained Infinite Horizon Model Predictive Control: Standard vs. Feedback Formulation*. University of Barcelona, 2001.
- [72] D. Megias, J. Serrano, and M.Y. Ghoumari. Extended linearized predictive control: practical control algorithms for non-linear systems. In *Proceedings of the 5th European Control Conference*, 1999.
- [73] U. C. Moon, S. C. Lee, and K. Y. Lee. An adaptive dynamic matrix control of a boiler-turbine system using fuzzy inference. In *14th International Conference on Intelligent System Applications to Power Systems*, Kaohsiung, Taiwan, 2007.

- [74] M. Morari and J. H. Lee. Model predictive control: Past, present and future. In *Proc. of PSE/Escape '97*, Trondheim, 1997.
- [75] A. Niederliński, J. Mościński, and Z. Ogonowski. *Regulacja adaptacyjna*. PWN, 1995.
- [76] M. Norgaard, O. Ravn, N.K. Poulsen, and L.K. Hansen. *Neural Networks for Modeling and Control of Dynamic Systems*. Springer, London, 2000.
- [77] B. A. Ogunnaike and W. H. Ray. *Process Dynamics, Modeling and Control*. Oxford University Press, 1994.
- [78] S. Osowski. *Sieci neuronowe w ujęciu algorytmicznym*. WNT, Warszawa, 1996.
- [79] P.D. Patterson. Obtaining improved efficiency and reduced LOI using advanced combustion optimizer on a boiler optimization in load-following mode. In *Conference on Unburned Carbon in Fly Ash*, 1999. [http://www.netl.doe.gov/publications/proceedings/pro\\_toc.html](http://www.netl.doe.gov/publications/proceedings/pro_toc.html).
- [80] S. Piche, B. Sayyar-Rodsari, D. Johnson, and M. Gerules. Nonlinear model predictive control using neural networks. *Control Systems Magazine*, 20(3):53–62, czerwiec 2000.
- [81] A. Piegat. *Modelowanie i sterowanie rozmyte*. Akademicka Oficyna Wydawnicza EXIT, Warszawa, 1999.
- [82] S. Plamowski. *Wdrażanie zaawansowanych układów regulacji w strukturze przetwarzanej*. rozprawa doktorska. Politechnika Warszawska, Warszawa, 2006.
- [83] S. Plamowski and P. Tatjewski. Safe implementation of advanced control in a diagnostic-based switching structure. In *IFAC*, 2006.
- [84] D. M. Prett and R. D. Gillette. Optimization and constrained multivariable control of catalytic cracking unit. In *Proc. Joint Automatic Control Conference*, San Fransisco, 1980.
- [85] Qin and Badgwell. An overview of industrial model predictive control technology. In *Fifth International on Chemical Process Control*, pages 232–256, 1997.

- 
- [86] Qin and Badgwell. A survey of industrial model predictive control technology. *Control Engineering Practice*, 11:733–764, 2003.
- [87] Z. Qiping, G. Jinbiao, W. Xiangyu, and W. Youhua. An industrial application of APC technique in fluid catalytic cracking process control. In *SICE 2003 Annual Conference*, volume 1, pages 530–534, 2003.
- [88] J. Rakowski. *Automatyka cieplnych urządzeń siłowni*. WNT, Warszawa, 1980.
- [89] Ch. V. Rao and J. B. Rawling. Steady states and constraints in model predictive control. *AIChE Journal*, 45(6):1266–1278, 1999.
- [90] P.D. Roberts. An algorithm for steady-state optimization and parameter estimation. *Int. Journal of Systems Science*, 1979.
- [91] D. Seaborg, T. Edgar, and D. Mellichamp. *Process Dynamics and control*. John Wiley and Sons, Inc., 1989.
- [92] T. Soderstrom and P. Stoica. *Identyfikacja systemów*. Wydawnictwo Naukowe PWN, Warszawa, 1997.
- [93] Eldra P. Solomon, Linda R. Berg, Diana W. Martin, and Claude A. Vilee. *Biology*. Saunders College Publishing, Fort Worth, Texas, USA, 3-rd edition, 1993.
- [94] T. Stibor, J. Timmis, and C. Eckert. A comparative study of real-valued negative selection to statistical anomaly detection techniques. In *ICARIS*, 2005.
- [95] R. Tadeusiewicz. *Sieci neuronowe*. Akademicka Oficyna Wydawnicza, Warszawa, 1993.
- [96] T. Takagi and M. Sugeno. Fuzzy identification of systems and its application to modeling and control. *Trans. On Systems, Man and Cybernetics*, 1985.
- [97] P. Tatjewski. *Wybrane metody numeryczne*. Skrypt do przedmiotu Metody Numeryczne i Symulacja Komputerowa, Warszawa, 1999.
- [98] P. Tatjewski. Iterative optimizing set-point control – the basic principle redesigned. In *Proc. of 15th IFAC Triennial World Congress*, Barcelona, 2002.

- [99] P. Tatjewski. *Sterowanie zaawansowane obiektów przemysłowych, Struktury i algorytmy*. Akademicka Oficyna Wydawnicza EXIT, Warszawa, 2002.
- [100] P. Tatjewski. *Advanced Control of Industrial Processes: Structures and Algorithms*. Springer Verlag, London, 2007.
- [101] P. Tatjewski. Advanced control and on-line optimization in multilayer structures. *Annual Reviews in Control*, 32:71–85, 2008.
- [102] P. Tatjewski and M. Lawryńczuk. Soft computing in model-based predictive control. *Int. J. Appl. Math. Comp. Sci.*, 2006.
- [103] P. Tatjewski and P.D. Roberts. Newton-like algorithm for integrated system optimization and parameter estimation technique. *Int. Journal of Control* 46(4), 1987.
- [104] J. Timmis, M. Neal, and T. Knight. Aine: Machine learning inspired by the immune system. *IEEE Transactions on Evolutionary Computation*, 2002.
- [105] L. Trybus. Stacje procesowe systemów sterowania w energetyce. In *VII Konferencja Automatyków*, Rytró, 2003.
- [106] L. Trybus. Funkcje stacji inżynierskich w systemach sterowania dla energetyki. In *VIII Konferencja Automatyków*, Rytró, 2004.
- [107] L. Trybus. Systemy sterowania w energetyce. In *IX Konferencja Automatyków*, Warszawa, 2005.
- [108] V. Vapnik. *Statistical Learning Theory*. Wiley, 1998.
- [109] V. Vapnik. *The nature of statistical learning theory*. Springer, 1999.
- [110] S. Wierzchoń. *Sztuczne Systemy Immunologiczne – Teoria i Zastosowania*. Exit, Warszawa, 2001.
- [111] S. T. Wierzchoń. Immune algorithms in action: Optimization of non-stationary functions. In *SzI-16’2001: XII Ogólnopolskie Konwersatorium nt. Sztuczna Inteligencja – nowe wyzwania (badania – zastosowania – rozwój)*, pages 97–106, Siedlce–Warszawa, Polska, listopad 2001. <http://www.ipipan.eu/staff/s.wierzchon/ais/index.html>, in Polish.

- 
- [112] J. Williams and K. Świrski. Closed loop  $NO_x$  control and optimization using neural networks. In *V-th Instrumentation, Controls and Automation in Power Industry Conference*, volume 41, pages 111–121, Scottsdale, USA, czerwiec 1998.
- [113] K. Wojdan, T. Chomiak, G. Jarmoszewicz, and K. Świrski. Sztuczny system immunologiczny jako optymalizator procesu spalania. In *VII Konferencja – Problemy badawcze energetyki cieplnej*, pages 53–62, Warszawa, grudzień 2005. Oficyna Wydawnicza Politechniki Warszawskiej.
- [114] K. Wojdan, T. Chomiak, G. Jarmoszewicz, and K. Świrski. Zastosowanie systemu SILO (algorytmy immunologiczne) do optymalizacji procesu spalania w elektrowni Newton. In *VIII Konferencja – Problemy badawcze energetyki cieplnej*, Warsaw, 2007. Oficyna Wydawnicza Politechniki Warszawskiej.
- [115] K. Wojdan and K. Świrski. Immune inspired optimizer of combustion process in power boiler. In *New Trends in Applied Artificial Intelligence*, Lecture Notes in Computer Science, Kyoto, Japan, czerwiec 2007. Springer. Proc. of the 20th International Conference on Industrial, Engineering and Other Applications of Applied Intelligent Systems.
- [116] K. Wojdan, K. Świrski, and G. Jarmoszewicz. Stochastic immune layer optimizer – efficient tool for optimization of combustion process in a boiler. In *1-st International Conference on Bio Inspired models of Network, Information and Computing Systems – BIONETICS 2006*, Cavalese, Italy, grudzień 2006.
- [117] K. Wojdan, K. Świrski, and M. Warchoń. Immune inspired system for chemical process optimization using the example of a combustion process in a power boiler. In *14th International Conference on Intelligent System Applications to Power Systems*, Kaohsiung, Taiwan, 2007.
- [118] K. Wojdan, K. Świrski, and M. Warchoń. Zastosowanie optymalizatora opartego na teorii sztucznych systemów immunologicznych do sterowania procesem spalania w elektrowni. In *II konferencja naukowo-techniczna – Kontrola, Sterowanie i Automatyzacja Procesu Spalania w Kotłach Energetycznych*, Szczyrk, 2007.

- [119] K. Wojdan, K. Świrski, M. Warchoł, and T. Chomiak. New improvements of immune inspired optimizer SILO. In *Proc. of the 19th IEEE International Conference on Tools with Artificial Intelligence*, Patras, Grecja, październik 2007.
- [120] K. Wojdan, K. Świrski, M. Warchoł, G. Jarmoszewicz, and T. Chomiak. Bio-inspired process control. In *Bio-inspired computing and communication networks*, chapter 9. Taylor and Francis Group, 2009. przyjęte do publikacji.
- [121] J. Yen and R. Langari. *Fuzzy Logic – Intelligence, Control and Information*. Prentice Hall, 1999.
- [122] L.A. Zadeh. Fuzzy sets. *Information and Control*, 1965.
- [123] Z. Y. Zhao and M. Tomizuka. Fuzzy gain scheduling of PID controllers. *IEEE Transactions on Systems, Man, and Cybernetics*, 23:1392–1398, 1993.