

Politechnika Wrocławska
Wydział Informatyki i Zarządzania
Instytut Informatyki

Rozprawa doktorska

**Algorytm podejmowania decyzji z
wykorzystaniem identyfikacji
dwustopniowej**

Krzysztof Brzostowski

Promotor: prof. Jerzy Świątek

Wrocław, 2009

Profesorowi Jerzemu Świątkowi serdecznie dziękuję za przekazaną wiedzę i mądrość życiową. Najbliższym za wiarę.

Spis treści

Spis treści	i
1 Adaptacyjny algorytm podejmowania decyzji z wykorzystaniem identyfikacji dwustopniowej – sformułowanie problemu pracy	1
1.1 Wstęp	1
1.2 Geneza problemu	3
1.3 Rehabilitacja pacjentów cierpiących na spastyczność – aktualny stan badań	5
1.4 Adaptacyjny proces wspomaganie podejmowania decyzji dla obiektu statycznego	7
1.5 Zadanie identyfikacji obiektu statycznego	10
1.6 Zadanie identyfikacji dwustopniowego obiektu statycznego na potrzeby procesu wspomaganie podejmowania decyzji	15
1.7 Zadanie podejmowania decyzji	17
1.8 Zadanie rozpoznawania obiektów	17
1.9 Teza, cel i zakres pracy	19
1.10 Plan pracy	20
2 Adaptacyjny system podejmowania decyzji z wykorzystaniem identyfikacji dwustopniowej	23
2.1 Problem wspomaganie podejmowania decyzji dla zadania planowania rehabilitacji – opis problemu	23
2.2 Struktura adaptacyjnego systemu wspomaganie podejmowania decyzji z wykorzystaniem identyfikacji dwustopniowej	25

2.2.1	Model zespołu mięśni szkieletowych w stawie łokciowym – pierwszy stopień	29
2.2.2	Analiza wrażliwości modelu zespołu mięśni szkieletowych w stawie łokciowym	33
2.2.3	Identyfikacja modelu zespołu mięśni szkieletowych w stawie łokciowym – pierwszy stopień	36
2.2.4	Sformułowanie zadania identyfikacji modelu	37
2.2.5	Algorytm identyfikacji	38
2.2.6	Model wpływu procesu podejmowania decyzji na zmianę parametrów obiektu – drugi stopień	38
2.2.7	Identyfikacja modelu wpływu procesu podejmowania decyzji na zmianę parametrów obiektu – drugi stopień	40
2.2.8	Sformułowanie zadania identyfikacji modelu	41
2.2.9	Algorytm identyfikacji	41
2.3	Zadanie podejmowania decyzji	42
2.3.1	Sformułowanie problemu wspomaganie podejmowania decyzji	46
2.3.2	Algorytm wspomaganie podejmowania decyzji	47
2.3.3	Adaptacyjne zadanie wspomaganie podejmowania decyzji .	52
2.3.4	Sformułowanie problemu adaptacyjnego wspomaganie decyzji	52
2.3.5	Adaptacyjny algorytm wspomaganie podejmowania decyzji	54
2.3.6	Analiza zbieżności adaptacyjnego algorytmu wspomaganie podejmowania decyzji	56
2.3.7	Adaptacyjne zadanie wspomaganie podejmowania decyzji ze strojeniem parametrów	64
2.3.8	Sformułowanie problemu adaptacyjnego wspomaganie decyzji ze strojeniem parametrów	66
2.3.9	Adaptacyjny algorytm wspomaganie podejmowania decyzji ze strojnym parametrem	67
2.3.10	Analiza zbieżności adaptacyjnego algorytmu wspomaganie podejmowania decyzji ze strojnym parametrem	68
2.3.11	Adaptacyjne zadanie wspomaganie podejmowania decyzji z uaktualnianiem wiedzy eksperta	69
2.3.12	Sformułowanie problemu adaptacyjnego wspomaganie podejmowania decyzji z uaktualnianiem wiedzy eksperta . . .	71

2.3.13	Adaptacyjny algorytm wspomaganie podejmowania decyzji z uaktualnianiem wiedzy eksperta – wersja I	71
3	Badania eksperymentalne	73
3.1	Identyfikacja modelu zespołu mięśni szkieletowych w stawie łokciowym – pierwszy stopień	73
3.1.1	Opis stanowiska badawczego	73
3.1.2	Opis eksperymentu	76
3.2	Ocena wyników identyfikacji modelu zespołu mięśni szkieletowych w stawie łokciowym - pierwszy stopień	78
3.3	Analiza wrażliwości modelu zespołu mięśni szkieletowych w stawie łokciowym - pierwszy stopień	84
4	Badania symulacyjne	90
4.1	Badanie wpływu procesu podejmowania decyzji na parametry modelu zespołu mięśni szkieletowych – badania symulacyjne	91
4.1.1	Opis modelu symulacyjnego	91
4.2	Wyniki badań symulacyjnych	96
5	Podsumowanie i wnioski	109
5.1	Oryginalny wkład pracy w dziedzinie identyfikacji dwustopniowej i adaptacyjnego wspomaganie podejmowania decyzji	109
5.2	Proponowane kierunki przyszłych badań	112
	Bibliografia	114
	Wykaz ważniejszych oznaczeń	128
	Spis rysunków	132
	Spis tabel	136
	Skorowidz	137

Rozdział 1

Adaptacyjny algorytm podejmowania decyzji z wykorzystaniem identyfikacji dwustopniowej – sformułowanie problemu pracy

1.1 Wstęp

Współczesna teoria sterowania zajmuje się zagadnieniami związanymi z analizą i projektowaniem komputerowych systemów wspomagających podejmowanie decyzji [42]. Podstawowym zakresem tematycznym jest rozwiązywanie problemów związanych z projektowaniem algorytmów przetwarzających dostępne dane i podejmujących na tej podstawie decyzje. W początkowym okresie opracowywana metodologia wykorzystywana była głównie na potrzeby sterowania urządzeniami przemysłowymi. Następnie zaczęto wykorzystywać metody znane z analizy systemowej tj. modelowania, identyfikacji i rozpoznawania, co pozwoliło na projektowanie systemów charakteryzujących się większą efektywnością.

Pierwsze systemy komputerowe wykorzystywane w procesie wspomagania podejmowania decyzji zaprojektowano i zaczęto stosować w praktyce czterdzieści lat temu [130], [154], [155]. Obszar wykorzystania nowych metod nie ograniczał

się jedynie do realizacji przemysłowych czy z zakresu zarządzania i planowania.

Rozwój nauk medycznych również przyczynił się do przyspieszeniem prac nad metodami wspomaganie podejmowania decyzji. Wzrost zapotrzebowania na nowoczesne metody stawiania diagnoz medycznych można wiązać min. z postępowaniem w dziedzinie systemów doradczych wykorzystywanych przez lekarzy w codziennej praktyce.

Pierwsze systemy i programy komputerowe, które wykorzystano na potrzeby medycyny, stosowano głównie do statystycznej oceny wyników pomiarów [156].

Najnowsze systemy komputerowe wykorzystywane w medycynie usprawniają proces wspomaganie podejmowania decyzji w terapiach leczniczych na podstawie przeprowadzonej diagnozy chorego, która to diagnoza również wspomagana jest rozwiązaniami z zakresu analizy systemowej. W szeregu prac zostały opisane przykłady ich wykorzystania [13], [64], [87], [109].

Przy projektowaniu systemów doradczych dla lekarzy prowadzących terapię stosowanych jest kilka podejść. Jednym z pierwszych było wykorzystanie w projektowanych rozwiązaniach informacji statystycznej, którą pozyskiwało się głównie na bazie wcześniejszych badań klinicznych [156]. Wadą tego podejścia jest konieczność dysponowania obszernym zbiorem danych z przebiegu różnych procesów terapeutycznych. Problemem również może być niekompletność danych, które wykorzystane będą w procesie decyzyjnym.

Innym podejściem, bardzo popularnym i co więcej, zbliżonym do codziennej praktyki lekarskiej, jest budowanie systemów komputerowych naśladowujących postępowanie lekarzy. W systemach projektowanych zgodnie z tą koncepcją, dokonuje się analizy pozyskanej wiedzy o obiekcie oraz wbudowanej wiedzy terapeutycznej [156]. Podobnie jak lekarz analizujący konkretny przypadek medyczny również system wspomagający podejmowanie decyzji dokonuje operacji logicznej na dwóch zbiorach danych: zbiorze danych o pacjencie (zdobytej w wyniku diagnozy) oraz zbiorze o dostępnych metodach postępowania i terapii [156].

Warto również wspomnieć o korzyściach ekonomicznych, jakie wynikają z wykorzystania systemów wspomagających podejmowanie decyzji w praktyce lekarskiej. W tym wypadku można jedynie mówić o zyskach wówczas, gdy pod uwagę zostanie wzięty odpowiednio długi horyzont czasowy.

1.2 Geneza problemu

Lekarze zajmujący się rehabilitacją pacjentów bardzo często stają przed problemem zaplanowania odpowiedniej strategii działania. Wybór właściwego toku postępowania poprzedza się badaniem wstępnym, które pozwala badającemu ocenić aktualny stan zdrowia pacjenta i stanowi podstawę dalszych działań. Właściwa diagnoza i ocena aktualnego stanu zdrowia chorego jest ważnym etapem w procesie leczenia i ma wpływ na przebieg rehabilitacji.

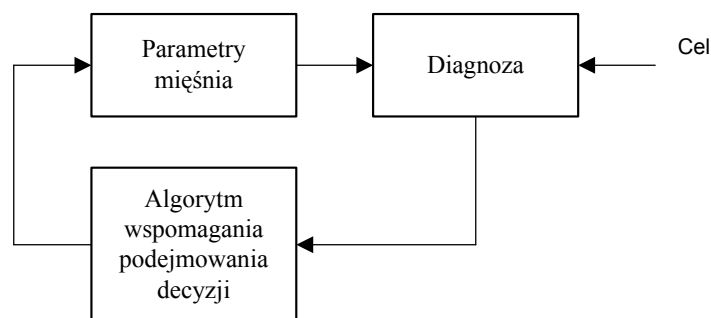
W praktyce lekarskiej do oceny stanu zdrowia pacjenta wykorzystywane są metody, które bazują na intuicji i doświadczeniu lekarza. W zadaniu planowania rehabilitacji spastyczności stawu łokciowego, które w prezentowanej pracy jest rozpatrywane, lekarze do opisu stopnia upośledzenia chorego człowieka wykorzystują skale opisowe.

Terapeuci i lekarze zajmującym się rehabilitacją osób cierpiących na spastyczność brakuje metod diagnozy, które opierałyby się, nie na subiektywnych odczuciach badającego, lecz na obiektywnych wynikach pomiarów. Dokonując wyboru wielkości mierzalnych, na podstawie których oparta będzie lekarska diagnoza, należy wybrać takie, które zawierają informację przydatną do oceny stanu zaawansowania choroby. Jest to bardzo ważne, ponieważ proces diagnozowania pacjenta stanowi podstawę do dalszego toku postępowania w procesie rehabilitacji.

Na (Rysunek 1.1) przedstawiono najprostszy schemat obrazujący sposób postępowania lekarza bądź fizjoterapeuty tj. bazując na informacji o aktualnej wartości parametrów mięśni szkieletowych dokonywany jest wybór najwłaściwszego postępowania. W tym celu porównuje się aktualną wartość parametrów mięśni badanego pacjenta z wartościami właściwymi osobom zdrowym.

Ponieważ w rozpatrywanym przypadku aktualna wartość parametrów mięśni szkieletowych nie jest dostępna bezpośrednio poprzez wykonanie pomiarów należy zaproponować rozwiązanie, które pozwoli na ich wyliczenie w sposób pośredni. W tym celu zaproponowano rozwiązanie bazujące na wykorzystaniu algorytmów identyfikacji. Odpowiednio zmodyfikowany schemat został przedstawiony na (Rysunek 1.2).

Na przedstawionym schemacie systemu wspomagania podejmowania decyzji należy zwrócić uwagę na model mięśni szkieletowych, którego parametry wyznaczone są na drodze identyfikacji z wykorzystaniem danych pomiarowych. Wyznaczone wartości modelu posłużą w kolejnym kroku – po dokonaniu diagnozy – do

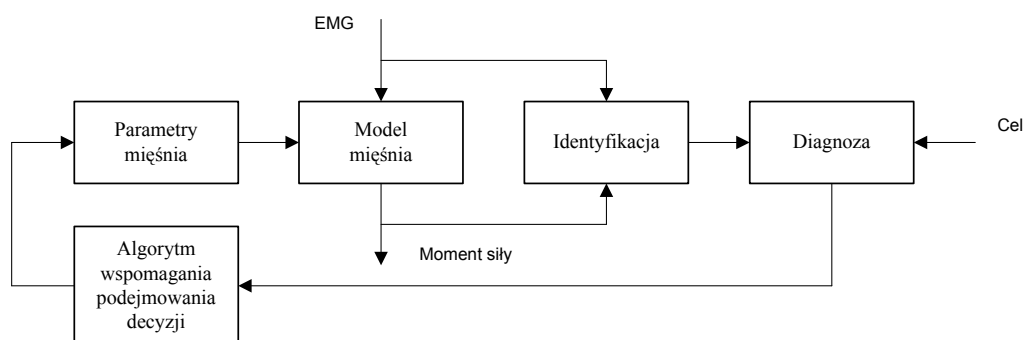


Rysunek 1.1: System z algorytmem wspomaganie podejmowania decyzji w procesie planowania rehabilitacji

podjęcia decyzji odnośnie działań lekarskich.

Warto również zwrócić uwagę na sygnały identyfikujące, które zostały wykorzystane do rozwiązania zadania estymacji parametrów modelu mięśni szkieletowych. Sygnałem wejściowym jest mierzony na powierzchni skóry sygnał EMG. Wyboru sygnału EMG dokonano ponieważ jest to sygnał niosący informację na temat aktualnych stanu mięśni szkieletowych. Co więcej, sygnał EMG podczas skurczów bądź rozkurczów zdrowego człowieka znacznie różni się od sygnału EMG właściwego osobom cierpiącym na spastyczność.

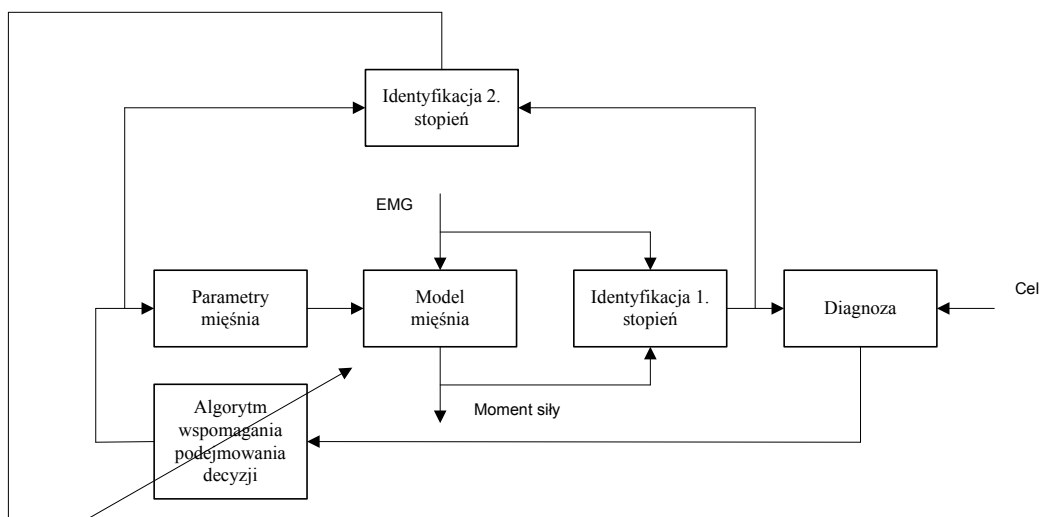
Jako sygnał wyjściowy w rozpatrywanym systemie przyjęto generowany przez staw łokciowy moment siły. Wymienione sygnały mierzone są jednocześnie.



Rysunek 1.2: System z modelem i algorytmem wspomaganie podejmowania decyzji w procesie planowania rehabilitacji

Ponieważ parametry mięśni w trakcie trwania procesu rehabilitacji ulegają

zmianie, zwiększenia efektywności procesu wspomaganego podejmowania decyzji można dokonać poprzez ustalenie zależności pomiędzy podjętym działaniem a parametrem charakteryzującym aktualny stan mięśni szkieletowych. Sytuacja ta została przedstawiona na (Rysunek 1.3). Przedstawiona koncepcja prowadzi do zadania identyfikacji dwustopniowej, która została opisana w podpunkcie 1.5.



Rysunek 1.3: Adaptacyjny system z modelem i algorytmem wspomaganym podejmowania decyzji w procesie planowania rehabilitacji

1.3 Rehabilitacja pacjentów cierpiących na spastyczność – aktualny stan badań

Spastyczność jest zaburzeniem ruchowym spowodowanym zwiększoną aktywnością *motoneuronów* (zwanymi także *neuronami motorycznymi* bądź *ruchowymi*). Schorzenie to może objawiać się min. *spazmem*, czyli niekontrolowanym i patologicznym skurczem mięśni szkieletowych [89]. Choroba ta związana jest z uszkodzeniem pewnych obszarów mózgu bądź rdzenia kręgowego, w których zlokalizowane są ośrodki odpowiedzialne za odruchy warunkowe. Zwykle do wywołania nieprawidłowości w działaniu i defektów dochodzi w wyniku udarów, pourazowych uszkodzeń mózgu lub rdzenia kręgowego oraz stwardnienia rozsianego [151].

Proces rehabilitacji pacjentów cierpiących na spastyczność jest zagadnieniem złożonym, w którym czynny udział bierze wieloosobowy zespół składający się

z neurologa, fizjoterapeuty i pielęgniarki [172]. Każda z wymienionych osób ma pewne zadania do wykonania, których celem jest poprawa stanu zdrowia pacjenta. Oprócz wymienionych osób bezpośrednio związanych z medycyną często w procesie terapeutycznym biorą również udział osoby zajmujące się psychologią i socjologią [172].

Metod leczenia spastyczności jest kilka. Wśród najpopularniejszych jest leczenie chirurgiczne oraz farmakologiczne. Metody te są skuteczne, ale posiadają one również wady. Główną wadą leczenia chirurgicznego jest niebezpieczeństwo powikłań, które zawsze może towarzyszyć zabiegom na sali operacyjnej, natomiast leczenie farmakologiczne nie może być stosowane dla wszystkich pacjentów – powodem mogą być przeciwwskazania do zażywania pewnych leków.

Alternatywą dla wyżej wymienionych metod rehabilitacji cierpiących na spastyczność jest *fizjoterapia*. Wśród najczęściej stosowanych metod możemy wyróżnić *ćwiczenia rehabilitacyjne* oraz *krioterapię*. Inne podejście, również skuteczne, to *elektroterapia*. Oczywiście wymienione metody mogą być stosowane łącznie w procesie rehabilitacyjnym.

Prekursorami leczenia spastyczność z wykorzystaniem elektrostymulacji był Hufschmidt [89]. Podczas swoich badań zauważył, że stymulacja elektryczna działa pobudzająco na ośrodki ruchowe. Wyniki uzyskane m.in. przez Hufschmidta, Cooka zainspirowały innych badaczy do podjęcia własnych badań co doprowadziło do opracowania wielu podejść w planowaniu terapii przez elektrostymulację.


W pracach dotyczących wpływu elektrostymulacji na poprawę stanu zdrowia pacjenta podkreśla się to, że scenariusze pobudzeń muszą być dobierane indywidualnie dla każdego pacjenta. Związane jest to z tym, że reakcje chorych na dany typ pobudzenia impulsami elektrycznymi mogą być różne. Zadaniem fizjoterapeuty bądź lekarza jest dobór odpowiedniego zestawu impulsów pobudzających.

Jedną z metod, która może zostać wykorzystana do rozwiązania zadania doboru impulsów pobudzających dla pacjenta jest zastosowanie modelowania matematycznego [153]. Wykorzystanie metod znanych z analizy systemowej w zadaniu ustalania scenariuszy pobudzających uszkodzone miejsca impulsami elektrycznymi związane jest z wykorzystaniem "stymulatorów", które stosowane są w terapii osób cierpiących na spastyczność [153]. Zastosowanie modelowania matematycznego w celu określenia optymalnego przebiegu procesu rehabilitacji może znacznie przyspieszyć ten proces [153], [111], [69].

1.4 Adaptacyjny proces wspomagania podejmowania decyzji dla obiektu statycznego


Opisany w podrozdziale 1.3 problem można rozwiązać sprowadzając go do zadania wspomagania podejmowania decyzji tj. do zadania polegającego na takim wyborze sekwencji działań, by możliwe było osiągnięcie zamierzonego celu przy jednoczesnej optymalizacji ustalonego wskaźnika. Wskaźnik ten w zależności od sytuacji może być minimalizowany lub maksymalizowany i będzie wykorzystany do oceny jakości procesu wspomagania podejmowanych decyzji.

Najprostszą strukturą, w której można realizować algorytm wspomagania podejmowania decyzji dla obiektu statycznego, jest system otwarty (Rysunek 1.4) [42].



Rysunek 1.4: Otwarty system z algorytmem wspomagania podejmowania decyzji

Kolejnym układem, w którym można realizować algorytm wspomagania podejmowania decyzji jest system zamknięty dla obiektu statycznego (Rysunek 1.5) [42].

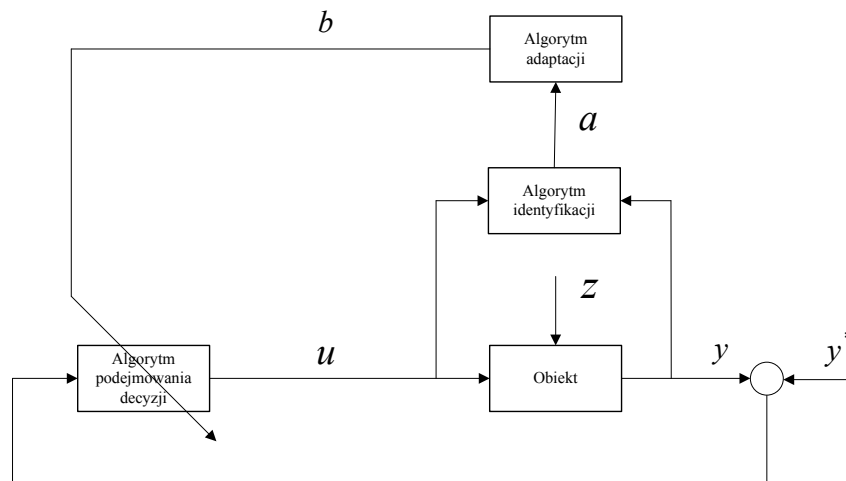


Rysunek 1.5: Zamknięty system z algorytmem wspomagania podejmowania decyzji

Zarówno dla pierwszego (Rysunek 1.4) jak i drugiego systemu (Rysunek 1.5) zadanie polega na wyznaczeniu decyzji $u \in \mathcal{U}$ dla obiektu w celu osiągnięcia zadanego sygnału wyjściowego $y \in \mathcal{Y}$ tj. y^* . Natomiast poprzez $z \in \mathcal{Z}$ oznaczono

zakłócenia wpływające na obiekt w trakcie procesu wspomaganego podejmowania decyzji.

W trakcie projektowania systemu wspomaganego podejmowania decyzji nie zawsze możliwe jest dokładne przewidzenie zachowania obiektu np. może być to spowodowane oddziałującymi na obiekt zakłóceniami z . Podejściem umożliwiającym zmniejszenie niepewności o obiekcie jest stopniowe zdobywanie dodatkowych informacji w czasie trwania procesu wspomaganego podejmowania decyzji [42]. Prowadzi to do koncepcji adaptacyjnego wspomaganego podejmowania decyzji, która jest następująca: podstawowy algorytm wspomaganego podejmowania decyzji charakteryzuje się dodatkowym parametrem b , który w trakcie działania systemu jest tak modyfikowany, aby zaprojektowany system działał w sposób optymalny [42]. Decyzja co do zmiany wartości parametru b może być podjęta na podstawie wartości parametru a charakteryzującego zależność pomiędzy wejściem u a wyjściem y obiektu (Rysunek 1.6). Mówimy wówczas o adaptacji poprzez identyfikację (również w rozdziale 2.3.7). W algorytmie adaptacyjnego wspomaganego podejmowania decyzji można wówczas wyróżnić dwie części: podstawowy algorytm wspomaganego podejmowania decyzji oraz algorytm adaptacji, który polepsza – z kroku na krok – jego działanie. Koncepcję adaptacyjnego systemu wspomaganego podejmowania decyzji przedstawiono na (Rysunek 1.6) [42].



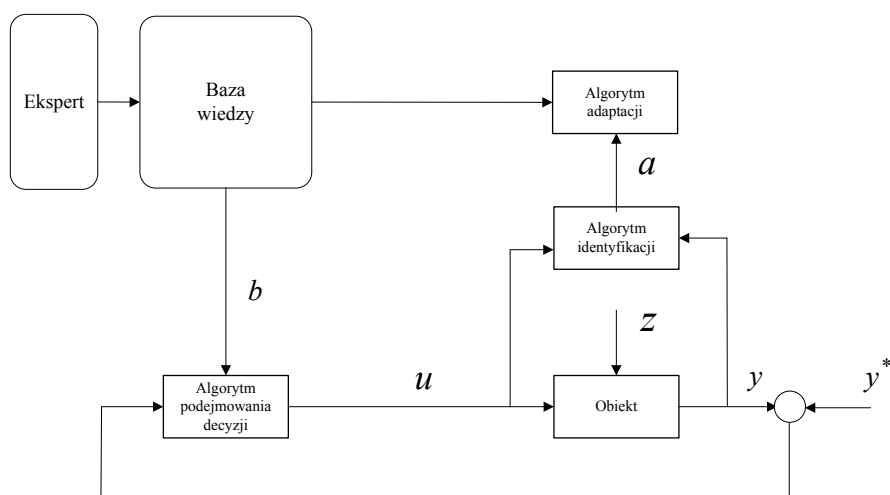
Rysunek 1.6: Adaptacyjne wspomaganie podejmowania decyzji w systemie zamkniętym

Warto zaznaczyć, że takt adaptacji różni się od taktu podstawowego algorytmu wspomaganego podejmowania decyzji i zwykle jest ona dokonywana rzadziej.

Kolejnym rozszerzeniem systemów wspomaganego podejmowania decyzji, oprócz idei adaptacyjnego poprawiania algorytmu, jest wykorzystanie w projektowanym systemie wiedzy eksperta. Koncepcja, którą zaproponowano w [5] prowadzi do systemów z reprezentacją wiedzy. Istnieją dwie główne koncepcje zaproponowanego podejścia tj.:

- systemy z reprezentacją wiedzy o obiekcie;
- systemy z reprezentacją wiedzy o wspomaganiu w podejmowaniu decyzji.

Ogólny schemat systemu wspomagającego podejmowanie decyzji z wiedzą eksperta przedstawiono na (Rysunek 1.7) [5]. Koncepcja systemów wspomagających podejmowanie decyzji z reprezentacją wiedzy została również poruszona w [42].



Rysunek 1.7: Adaptacyjne wspomaganie podejmowania decyzji w systemie zamkniętym z wiedzą eksperta


Omawiana koncepcja różni się od tej przedstawionej na (Rysunek 1.6) tym, że w systemie wykorzystana została baza wiedzy. W przedstawionym przypadku dodatkowa informacja pochodząca od eksperta używana jest do zmiany wartości wektora parametrów b . Oczywiście nie jest to jedyny sposób zastosowania bazy wiedzy w systemie wspomagającym podejmowanie decyzji. Dysponując odpowiednią informacją można zaproponować również system wspomagający podejmowanie decyzji, który bazując na dodatkowej informacji w kolejnych taktach

wyznaczają decyzje u .

W wielu praktycznych systemach wspomagających podejmowanie decyzji projektant systemu może spotkać się z sytuacją, w której koszt pomiaru pewnej wielkości wykorzystywanej w procesie jest bardzo wysoki bądź w ogóle nie jest możliwe przeprowadzenie odpowiednich eksperymentów pomiarowych. Wówczas do rozwiązania problemu może zostać wykorzystana idea identyfikacji dwustopniowej.

1.5 Zadanie identyfikacji obiektu statycznego

Celem zadania identyfikacji jest stworzenie z wykorzystaniem zebranych danych pomiarowych modelu matematycznego. Obiekt, dla którego w zadaniu identyfikacji ustala się zależność pomiędzy wielkościami $u^{(1)}, u^{(2)}, \dots, u^{(S)}$ oraz $y^{(1)}, y^{(2)}, \dots, y^{(L)}$, nazywa się obiektem identyfikacji. Natomiast wymienione wielkości $u^{(1)}, u^{(2)}, \dots, u^{(S)}$ oraz $y^{(1)}, y^{(2)}, \dots, y^{(L)}$ – odpowiednio – wielkościami wejściowymi oraz wyjściowymi (Rysunek 1.8).



Rysunek 1.8: Obiekt identyfikacji z wektorem wejść \mathbf{u} oraz wyjść \mathbf{y}

Na schemacie (Rysunek 1.8) wielkości wejściowe i wyjściowe przedstawiono w postaci S oraz L -wymiarowych wektorów, które zapisano poniżej:

$$\mathbf{u} = \begin{bmatrix} u^{(1)} \\ u^{(2)} \\ \vdots \\ u^{(S)} \end{bmatrix}, \mathbf{y} = \begin{bmatrix} y^{(1)} \\ y^{(2)} \\ \vdots \\ y^{(L)} \end{bmatrix}, \quad (1.1)$$

gdzie: \mathbf{u} – wektor wejść obiektu, $\mathbf{u} \in \mathcal{U} \subseteq \mathcal{R}^S$, \mathbf{y} – wektor wyjść obiektu, $\mathbf{y} \in \mathcal{Y} \subseteq \mathcal{R}^L$.

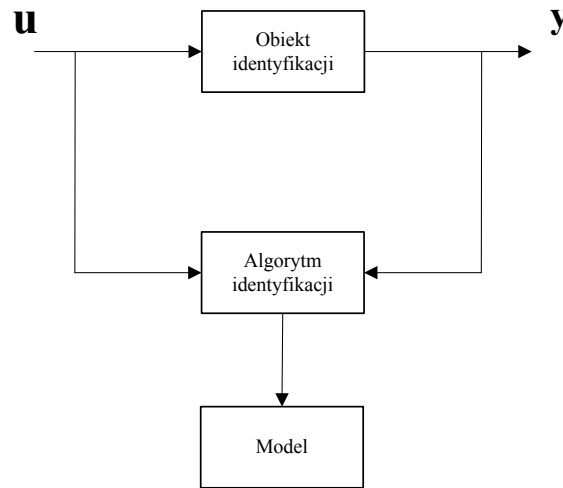
Powyżej wspomniano, że podstawą do określenia modelu matematycznego rozpatrywanego obiektu jest zestaw danych pomiarowych. W niniejszej podpunkcie rozpatrzono przypadek identyfikacji obiektu statycznego. Należy podkreślić, że dla obiektu dynamicznego rozważania są równoważne.

W wyniku przeprowadzonego eksperymentu uzyskano N pomiarów wyjść $\mathbf{y}(n)$ dla zadanego sygnału wejściowego $\mathbf{u}(n)$, gdzie $n = 1, 2, \dots, N$. Wyniki pomiarów zapisano w postaci:

$$\mathbf{U}_N = [\mathbf{u}(1) \quad \mathbf{u}(2) \quad \dots \quad \mathbf{u}(N)], \mathbf{Y}_N = [\mathbf{y}(1) \quad \mathbf{y}(2) \quad \dots \quad \mathbf{y}(N)], \quad (1.2)$$

gdzie \mathbf{U}_N oraz \mathbf{Y}_N są macierzami, których kolumny są wynikami kolejnych pomiarów – odpowiednio – wejść i wyjść.

Kolejnym krokiem, po dokonaniu pomiarów (1.2), jest zaproponowanie algorytmu przetwarzającego zgromadzone dane w celu wyznaczenia modelu obiektu. Na (Rysunek 1.9) przedstawiono układ identyfikacji, w skład którego obiekt identyfikacji wraz z identyfikatorem [167].



Rysunek 1.9: Układ identyfikacji

W wyniku analizy danych eksperymentalnych przyjęto model:

$$\bar{\mathbf{y}} = \Phi(\mathbf{u}; \mathbf{a}),$$

gdzie Φ jest zaproponowaną funkcją, która opisuje zależność wektora wejść \mathbf{u} od wektora wyjść modelu $\bar{\mathbf{y}}$.

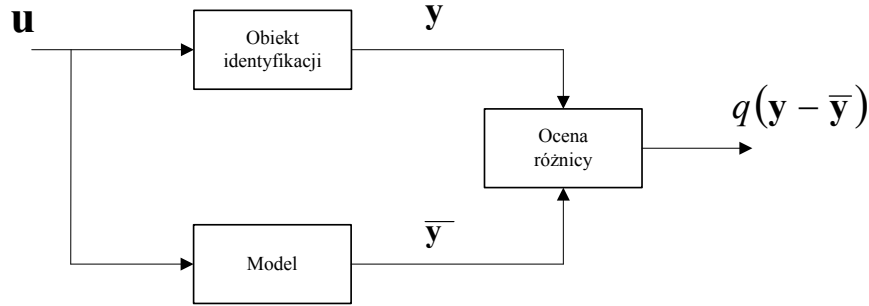
Na (Rysunku 1.10) został przedstawiony obiekt identyfikacji wraz z zaproponowanym modelem $\bar{\mathbf{y}} = \Phi(\mathbf{u}; \mathbf{a})$.

Dla opisanego powyżej zadania, identyfikacja polega na wyznaczeniu takich wartości wektora parametrów modelu \mathbf{a} by oceniona różnica pomiędzy wartością

wektora wyjściowego $\bar{\mathbf{y}}$ – wyliczonego na podstawie modelu tj.:

$$\bar{\mathbf{Y}}_N = [\bar{\mathbf{y}}(1) \quad \bar{\mathbf{y}}(2) \quad \dots \quad \bar{\mathbf{y}}(N)]$$

a zmierzoną wartością wyjścia obiektu \mathbf{y} przy ustalonym wejściu \mathbf{u} była minimalna w sensie przyjętego kryterium jakości identyfikacji Q .



Rysunek 1.10: Wybór optymalnego modelu

Wskaźnik jakości identyfikacji Q przyjęto w postaci:

$$Q(\bar{\mathbf{U}}_N, \bar{\mathbf{Y}}_N; \mathbf{a}) = q(\mathbf{Y} - \bar{\mathbf{Y}}), \quad (1.3)$$

gdzie $q(\cdot, \cdot)$ to funkcja, której wartość jest miarą różnicy pomiędzy zmierzonym sygnałem wyjściowym obiektu z odpowiednim sygnałem z wyjścia modelu dla $n = 1, 2, \dots, N$.

Dla ustalonego zestawu danych pomiarowych $\bar{\mathbf{U}}_N, \bar{\mathbf{Y}}_N$, wskaźnika jakości Q oraz modelu Φ można sformułować zadanie optymalizacji poszukiwania optymalnego wektora wartości parametrów \mathbf{a} :

$$Q(\mathbf{a}^*) = \min_{\mathbf{a}} Q(\mathbf{a}). \quad (1.4)$$

W wyniku rozwiązania powyższego zadania (1.4) otrzymujemy algorytm identyfikacji:


$$\mathbf{a}^* = \Psi(\bar{\mathbf{U}}_N, \bar{\mathbf{Y}}_N). \quad (1.5)$$

Należy podkreślić, że uzyskane rozwiązanie jest optymalne dla zadanej serii pomiarowej $\bar{\mathbf{U}}_N, \bar{\mathbf{Y}}_N$, wskaźnika jakości Q oraz modelu Φ . Dysponując odpowiednim algorytmem identyfikacji Ψ dla zadanego obiektu identyfikacji możemy zaproponować układ identyfikacji, który przedstawiono na (Rysunek 1.9).

Zadanie identyfikacji dwustopniowego obiektu statycznego

W podrozdziale 1.4 zaznaczono, że w wielu praktycznych zadaniach identyfikacji nie jest możliwy bezpośredni pomiar pewnej interesującej wielkości rozpatrywanego obiektu. Problem może być związany z dużym kosztem eksperymentu identyfikacyjnego bądź ograniczeniami technicznymi. Brak możliwości wyznaczenia zadanego parametru obiektu prowadzi do koncepcji identyfikacji dwustopniowej, która umożliwia określenie jego wartości w sposób pośredni.

Na (Rysunek 1.11) przedstawiono dwustopniowy obiekt identyfikacji [165]:



Rysunek 1.11: Dwustopniowy obiekt identyfikacji

opisany następującym zestawem równań:

$$\mathbf{y} = \Phi_1(\mathbf{u}_1; \mathbf{a}_1), \quad (1.6)$$

$$\mathbf{a}_1 = \Phi_2(\mathbf{u}_2; \mathbf{a}_2), \quad (1.7)$$

gdzie:

$\mathbf{u}_1 \in \mathcal{U}_1 \subseteq \mathcal{R}^{S_1}$ – sygnał wejściowy na 1. stopniu o S_1 składowych;

$\mathbf{u}_2 \in \mathcal{U}_2 \subseteq \mathcal{R}^{S_2}$ – sygnał wejściowy na 2. stopniu o S_2 składowych;

$\mathbf{a}_1 \in \mathcal{A}_1 \subseteq \mathcal{R}^{R_1}$ – wektor parametrów na 1. stopniu o R_1 składowych;

$\mathbf{a}_2 \in \mathcal{A}_2 \subseteq \mathcal{R}^{R_2}$ – wektor parametrów na 2. stopniu o R_2 składowych;

$\mathbf{y} \in \mathcal{Y} \subseteq \mathcal{R}^L$ – sygnał wyjściowy na 1. stopniu o L składowych;

$\Phi_1 : \mathcal{R}^{S_1} \times \mathcal{R}^{R_1} \longrightarrow \mathcal{R}^L$;

$\Phi_2 : \mathcal{R}^{S_2} \times \mathcal{R}^{R_2} \longrightarrow \mathcal{R}^{R_1}$.

Istota koncepcji identyfikacji dwustopniowej, która wstępnie została sformułowana w pracach [32], [34], [35] a następnie rozwijana min. w pracach [1], [47],

[48], [70], [71], [72], [160], [161], [162], [164], [165], [168], [169] jest następująca: wybieramy pewien proces lub zjawisko i dla wyróżnionych wielkości wejściowych \mathbf{u}_1 oraz wyjściowych \mathbf{y} ustalamy wartości pewnego wektora parametrów \mathbf{a}_1 . Opisany schemat dotyczy identyfikacji na pierwszym z wyróżnionych stopni. W kolejnym kroku dokonujemy zmiany wielkości \mathbf{u}_2 , która to wielkość podczas identyfikacji na pierwszym stopniu była stała. Po zmianie na drugim z rozpatrywanych stopni wielkości \mathbf{u}_2 ponownie dokonujemy identyfikacji na pierwszym stopniu.

Przeprowadzając wielokrotnie identyfikację na pierwszym stopniu otrzymujemy zestaw danych, które umożliwiają wyznaczenie zależności pomiędzy wielkością \mathbf{u}_2 a wektorem parametrów \mathbf{a}_1 opisującą zależność pomiędzy sygnałem wejściowym i wyjściowym na pierwszym stopniu. W wyniku wykonania opisanego powyżej zadania otrzymujemy wartość wektora \mathbf{a}_2 , który charakteryzuje powyższą zależność.

Po przeprowadzeniu eksperymentu identyfikacyjnego dla ustalonej wartości wejścia na drugim stopniu \mathbf{u}_2 uzyskamy sekwencję wyników pomiarów wejścia \mathbf{u}_1 oraz wyjścia \mathbf{y} na pierwszym stopniu:

$$\mathbf{U}_{1N_1, n_2} = [\mathbf{u}_{11, n_2} \quad \mathbf{u}_{12, n_2} \quad \dots \quad \mathbf{u}_{1N_1, n_2}], \quad (1.8)$$

$$\mathbf{Y}_{N_1, n_2} = [\mathbf{y}_{1, n_2} \quad \mathbf{y}_{2, n_2} \quad \dots \quad \mathbf{y}_{N_1, n_2}], \quad (1.9)$$

gdzie: N_1 jest liczbę powtórzeń eksperymentu na pierwszym stopniu dla n_2 -tego eksperymentu na stopniu drugim, $n_2 = 1, 2, \dots, N_2$.

Wykorzystując zaproponowany algorytm identyfikacji na pierwszym stopniu Ψ_1 oraz dane pomiarowe (1.8) oraz (1.9) przy ustalonym sygnale wejściowym na stopniu drugim tj. $\mathbf{u}_{2N_2} = \mathbf{u}_{2n_2}$ dla $n_2 = 1, 2, \dots, N_2$ uzyskujemy optymalną wartość wektora parametrów \mathbf{a} :

$$\mathbf{a}_{1N_1, n_2}^* = \Psi_{1N_1, n_2}(\mathbf{U}_{1N_1, n_2}, \mathbf{Y}_{N_1, n_2}). \quad (1.10)$$

Następnie, powtarzając identyfikację na pierwszym stopniu dla różnych wartości wejścia na stopniu drugim, czyli $\mathbf{u}_{2N_2} = \mathbf{u}_{2n_2}$ dla $n_2 = 1, 2, \dots, N_2$, uzyskujemy sekwencję wyjściową dla drugiego stopnia:

$$\mathbf{A}_{1N_1, N_2}^* = [\mathbf{a}_{1N_1, 1}^* \quad \mathbf{a}_{1N_1, 2}^* \quad \dots \quad \mathbf{a}_{1N_1, N_2}^*], \quad (1.11)$$

przy zadanej sekwencji wejściowej:

$$\mathbf{U}_{2N_1, N_2} = [\mathbf{u}_{2N_1, 1} \quad \mathbf{u}_{2N_1, 2} \quad \dots \quad \mathbf{u}_{2N_1, N_2}], \quad (1.12)$$

gdzie: N_1, N_2 jest liczbą powtórzeń eksperymentu identyfikacyjnego – odpowiednio – na pierwszym i drugim stopniu.

Biorąc pod uwagę dane pomiarowe (1.11), (1.12) oraz algorytm identyfikacji dla stopnia drugiego tj. Ψ_2 wyznaczamy wartości optymalne wektora parametrów \mathbf{a}_2 charakteryzujących zależność na drugim stopniu rozpatrywanego obiektu:

$$\mathbf{a}_{2N_2}^* = \Psi_{2N_2}(\mathbf{U}_{2N_1, N_2}, \mathbf{A}_{1N_1, N_2}^*). \quad (1.13)$$

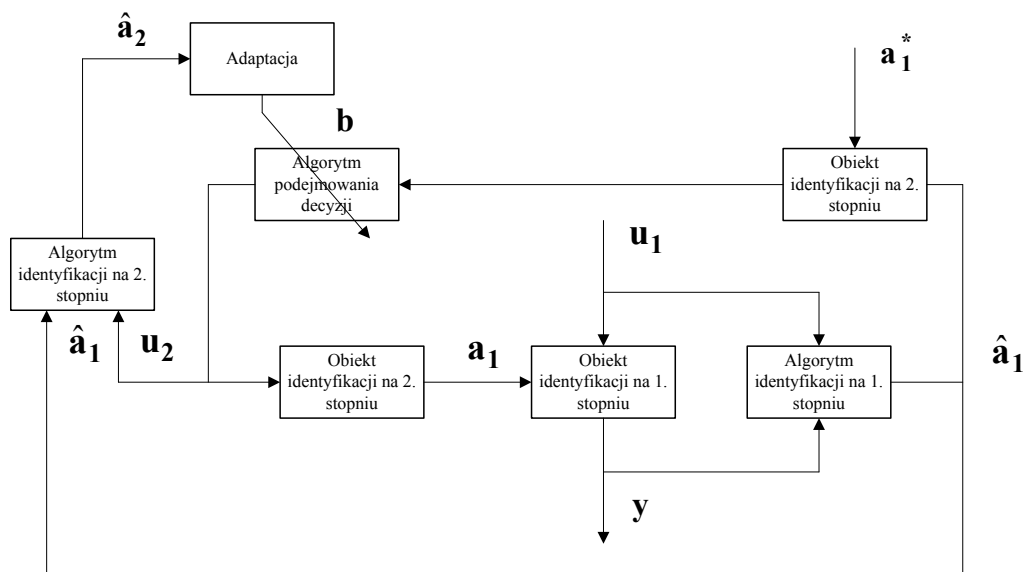
Należy zwrócić uwagę, że wyjście na drugim stopniu nie jest mierzone, jest natomiast wynikiem obliczeń zgodnie z algorytmem identyfikacji na stopniu pierwszym.

1.6 Zadanie identyfikacji dwustopniowego obiektu statycznego na potrzeby procesu wspomaganie podejmowania decyzji

W poprzednim podpunkcie 1.5 opisana została idea identyfikacji obiektu dwustopniowego. Jednym z możliwych zastosowań przedstawionego podejścia jest wykorzystanie go w zadaniu wspomaganie podejmowania decyzji. Najczęściej identyfikacji poddawany jest obiekt na drugim stopniu, który następnie wykorzystywany jest w zadaniu wspomaganie podejmowania decyzji tj. \mathbf{u}_2 jest działaniem, natomiast \mathbf{a}_1 wielkością sterowaną. Algorytm identyfikacji na drugim stopniu tj. Ψ_2 pozwala na ustalenie zależności pomiędzy \mathbf{u}_2 oraz \mathbf{a}_1 .

W podrozdziale 1.2 na (Rysunek 1.3) przedstawiono adaptacyjny system z modelem mięśni szkieletowych wykorzystujący algorytm wspomaganie podejmowania decyzji w procesie rehabilitacji. Zaproponowaną strukturę można przedstawić w bardziej formalny sposób, co zostało pokazane na (Rysunek 1.12) [160], w którym wielkości $\mathbf{u}_1, \mathbf{u}_2, \mathbf{y}, \mathbf{a}_1$ oraz \mathbf{a}_2 są zgodnie z opisem z podrozdziału 1.5. Natomiast \mathbf{b} to wektor parametrów wyznaczany przez adaptator na podstawie bieżącej wartości wektora parametru $\hat{\mathbf{a}}_2$.

W zagadnieniach związanych z wymienioną powyżej dziedziną wiedzy wyróżnić należy dwa główne nurty. Pierwszy z nich związany jest z dekompozycją systemów złożonych [77], natomiast drugi z nich znalazł zastosowanie z hierar-



Rysunek 1.12: System adaptacyjnego wspomagania podejmowania decyzji z identyfikacją dwustopniową

chicznych systemach identyfikacji [62], [63], [133], [134], [160]. W wymienionej pracy wykazano również, że koncepcję identyfikacji dwustopniowej łatwo rozszerzyć na przypadek ogólniejszy – identyfikację wielostopniową. W niniejszej pracy ograniczono się jedynie do przypadku dwustopniowego.

Istnieje wiele różnorodnych problemów rzeczywistych, w których wykorzystanie omawianej koncepcji identyfikacji dwustopniowej jest uzasadnione. Jednym z takich problemów może być zadanie ustalenia zależności pomiędzy podjętą decyzją a wewnętrznym parametrem charakteryzującym badany obiekt. Koncepcja ta jest szczególnie przydatna gdy bezpośrednie wyznaczenie interesującej wielkości jest niemożliwe bądź zbyt kosztowne.

Istotą koncepcji identyfikacji dwustopniowej jest dekompozycja rozpatrywanego zadania [160]. Rozróżnia się dwa przypadki tj. dekompozycję przestrzenną lub czasową, które mają ścisły związek z organizacją eksperymentu [160]. Opisywana w poprzednim podpunkcie idea identyfikacji dwustopniowej obiektów złożonych może zostać wykorzystana – tak jak w pracy – w zadaniu wspomagania podejmowania decyzji lub sterowania [160]. W problemie tym, pierwszy ze stopni pełni funkcje pomocniczą tj. można go rozpatrywać jako układ pomiarowy do wyznaczania wartości wektora parametrów \mathbf{a}_1 na podstawie zmierzonego sygnału

wejściowego i wyjściowego na tym stopniu. Dzięki właściwej organizacji obliczeń możliwe jest wyznaczenie zależności pomiędzy podjętą decyzją a wartością wektora parametrów \mathbf{a}_1 . W konsekwencji, wykorzystując omawianą koncepcję możliwa jest automatyzacja procesu wspomagania podejmowania decyzji lub sterowania [160].

1.7 Zadanie podejmowania decyzji

Opisane w poprzednim podpunkcie zadanie identyfikacji na pierwszym stopniu pełni funkcję pomocniczą w procesie wspomagania podejmowania decyzji. Otrzymany wynik wykorzystywany jest w zadaniu rozpoznawania lub klasyfikacji obserwowanych sytuacji czy też obrazów. Zadania tego dokonuje się na podstawie pewnej reguły lub zestawu reguł decyzyjnych. To, jakie reguły decyzyjne zostaną wykorzystane, zależy od tego, jak bogatą informacją *a priori* dysponuje projektant systemu.

W zadaniach, w których dysponuje się dostatecznie pełną informacją statystyczną można wykorzystać klasyczne metody znane z teorii decyzji statystycznych np. podejście bayesowskie. W zadaniach praktycznych zwykle nie można założyć, że dysponuje się wystarczająco bogatą informacją statystyczną. Wówczas rozwiązaniem są różnorodne metody, które bazują na uczeniu [53].

Rozpatrywany w pracy problem można przedstawić jako wieloetapowe zadanie wspomagania podejmowania decyzji. Jeśli ustalimy, że problem dotyczy obiektu stochastycznego a czas zakończenia zadania jest ustalony i wynosi K , to: Zadanie polega na znalezieniu optymalnego ciągu decyzji tj.:

$$(\mathbf{u}^*(1), \mathbf{u}^*(2), \dots, \mathbf{u}^*(K - 1)),$$

przy czym $\mathbf{u}^*(k) \in \mathcal{U}$, gdzie \mathcal{U} jest zbiorem dostępnych decyzji.

Dla ustalonego wskaźnika jakości $Q^{pd}(\cdot; \cdot)$ postaci otrzymujemy odpowiedni algorytm wspomagania podejmowania decyzji ψ^{pd} bazujący na bieżących wartościach wektora stanu.

1.8 Zadanie rozpoznawania obiektów

Zadanie rozpoznawania polega na przypisaniu każdemu wektorowi zmierzonych cech $\mathbf{x} \in \mathcal{X}$ numer klasy $i \in \mathcal{M}$ co można zapisać [97]:

$$i = \Psi_{PR}(\mathbf{x}), \quad (1.14)$$

Wektor cech, na podstawie którego rozwiązuje się zadanie rozpoznawania zapisujemy w postaci:

$$\mathbf{x} = \begin{bmatrix} x^{(1)} \\ x^{(2)} \\ \vdots \\ x^{(R_R)} \end{bmatrix} \in \mathcal{X} \subseteq \mathcal{R}^{R_R}, \quad (1.15)$$


Natomiast zbiór klas, które wykorzystywane są w zadaniu rozpoznawania ma postać:

$$i \in \{1, 2, \dots, M\} = \mathcal{M}, \quad (1.16)$$

gdzie M jest liczbą rozpatrywanych klas. Algorytm rozpoznawania dokonuje odwzorowania przestrzeni cech \mathcal{X} w zbiór numerów klas tj.:

$$\Psi_{PR} : \mathcal{X} \rightarrow \mathcal{M}.$$

Na (Rysunek 1.13) przedstawiono obiekt rozpoznawania wraz z wejściowym wektorem cech \mathbf{x} oraz wyjściowym numerem klasy i .



Rysunek 1.13: Obiekt rozpoznawania z wejściowym wektorem cech \mathbf{x} oraz wyjściowym numerem klasy i

Dla zadania rozpoznawania obiektów rozpatruje się dwa przypadki tj.:

- z pełną informacją probabilistyczną;
- z niepełną informacją probabilistyczną.

Pierwszy z przypadków zakłada znajomość prawdopodobieństwa *a priori* klas oraz warunkowych gęstości cech w klasach. Ponieważ w rzeczywistych zadaniach zwykle powyższe informacje nie są dostępne, co oznacza że przydatność metod bazujących na tych danych jest niewielka i nie będą one rozpatrywane w niniejszej pracy.

Drugie z podejść zakłada, że dostępny jest ciąg uczący, który można wykorzystać w zadaniu rozpoznawania. Pomimo, że utworzenie odpowiedniego ciągu uczącego może wymagać sporo wysiłku, utworzenie odpowiedniego jest jednak zadaniem wykonalnym.

Poniżej sformułowano problem rozpoznawania obiektów ze zbiorem uczącym.

Założmy istnienie ciągu uczącego postaci:

$$\mathbf{X}^{K_R} = \{(\mathbf{x}_1, i_1), (\mathbf{x}_2, i_2), \dots, (\mathbf{x}_{K_R}, i_{K_R})\}, \quad (1.17)$$

gdzie $\mathbf{x}_j \in \mathcal{X}$ wektor wartości cech dla danego obiektu uczącego, natomiast $i_j \in \mathcal{M}$ to numer klasy, z której odpowiedni obiekt pochodzi.

Ostatecznie, otrzymujemy algorytm rozpoznawania ze zbiorem uczącym \mathbf{X}^{K_R} w postaci:

$$i = \Psi_{PR}(\mathbf{x}, \mathbf{X}^{K_R}). \quad (1.18)$$

Konkretna postać algorytmu rozpoznawania ze zbiorem uczącym (1.18) zależy od tego, jaką metodę uczenia rozpoznawania wykorzystano.

1.9 Teza, cel i zakres pracy

Celem pracy jest opracowanie metodyki tworzenia algorytmów wspomagających podejmowanie decyzji w oparciu o dwustopniowy model obiektu.

1. W pracy należy zaproponować model zespołu mięśni szkieletowych z uwzględnieniem procesu rehabilitacji, który dla pierwszego stopnia ma postać:

$$\bar{\mathbf{y}} = \Phi_1(\mathbf{u}_1; \mathbf{a}_1), \quad (1.19)$$

natomiast dla drugiego:

$$\bar{\mathbf{a}}_1 = \Phi_2(\mathbf{u}_2; \mathbf{a}_2); \quad (1.20)$$

2. Zbadać przydatność zaproponowanego modelu w procesie diagnozy;

3. Wyznaczyć algorytmy identyfikacji do estymacji parametrów modeli (1.19), (1.20) na pierwszym i drugim stopniu na podstawie dostępnych danych pomiarowych. Algorytmy te mają być optymalne w sensie przyjętych kryteriów Q_1 oraz Q_2 odpowiednio;

4. Należy zaproponować adaptacyjny algorytm wspomaganie podejmowania decyzji z wykorzystaniem wiedzy eksperta;
5. Dla zaproponowanego algorytmów przeprowadzić badania symulacyjne, które pozwolą na porównanie zaproponowanego podejścia z innymi znanymi procedurami.

W pracy stawiana jest następująca teza:

”Zastosowanie algorytmów identyfikacji dwustopniowej oraz metod rozpoznawania obiektów umożliwi tworzenie efektywnych algorytmów wspomaganie podejmowania decyzji.”

1.10 Plan pracy

W celu rozwiązania postawionego problemu został zaproponowany adaptacyjny system wspomaganie podejmowania decyzji z wykorzystaniem identyfikacji dwustopniowej. Jako przykład wykorzystania opracowanej struktury rozpatrzono zadanie planowania rehabilitacji osób cierpiących na spastyczność, dla którego w niniejszej pracy:

1. Opracowano koncepcję adaptacyjnego systemu wspomagającego podejmowanie decyzji z identyfikacją dwustopniową i z wykorzystaniem wiedzy eksperta;
2. Opracowano adaptacyjny algorytm podejmowania decyzji z wykorzystaniem identyfikacji i metod rozpoznawania;
3. Opracowano zmodyfikowany adaptacyjny algorytm podejmowania decyzji z wykorzystaniem modelu na drugim stopniu;
4. Opracowano zmodyfikowany adaptacyjny algorytm podejmowania decyzji z uaktualnianiem bazy wiedzy;
5. Opisano zadanie identyfikacji na pierwszym i drugim stopniu obiektu dwustopniowego oraz zaproponowano algorytmy wyznaczania parametrów wykorzystane-

go modelu;

6. Opracowano programy komputerowe, które realizują algorytmy identyfikacji z punktu 5 oraz algorytmów wspomaganie podejmowania decyzji z punktu 2 oraz jego modyfikacji z punktów 3 i 4;

7. Dla dostępnych danych pomiarowych dokonano oceny przydatności modelu na pierwszym stopniu w celu dokonania diagnozy;

8. Opisano metodę badania wrażliwości modelu na pierwszym stopniu na zmianę jego parametrów;

9. Wykorzystując model zaczerpnięty z literatury zaprojektowano środowisko symulacyjne do oceny opracowanego adaptacyjnego algorytmu podejmowania decyzji;

10. Przeprowadzono formalną analizę stabilności opracowanego adaptacyjnego algorytmu podejmowania decyzji;

Wymienione rezultaty omówiono w kolejnych rozdziałach pracy, której układ jest następujący:

Rozdział pierwszy ma charakter wstępny. Zawarto w nim opis zaproponowanego adaptacyjnego systemu podejmowania decyzji dla obiektu dwustopniowego. Opisano również krótko problem medyczny, dla rozwiązania którego wykorzystano wspomniany system wspomagający podejmowane decyzji. Określono co jest obiektem identyfikacji oraz sformułowano zadania identyfikacji, które należy rozwiązać na każdym ze stopni. Opisano również zadanie wspomaganie podejmowania decyzji w zaproponowanym systemie oraz algorytmy, które zostaną wykorzystane do jego rozwiązania.

Dzięki dokonaniu opisu możliwe było precyzyjne sformułowanie celu pracy, co zostało dokonane w końcu rozdziału pierwszego.

Rozdział drugi zawiera opis zadań, które należy rozwiązać w zaproponowanym adaptacyjnym systemie podejmowania decyzji. Pierwszą część poświęcono problemowi ustalania klasy modeli zarówno na pierwszym jak i drugim stopniu rozpatrywanego obiektu. Opisano również algorytmy identyfikacji, które zostały

wykorzystane do wyboru najlepszego modelu z określonej klasy dla zaproponowanego wskaźnika jakości i dla ustalonych danych pomiarowych.

Ponieważ pierwszy ze stopni w zaproponowanym systemie pełni funkcję pomocniczą i jest wykorzystany w zadaniu stawiania diagnozy, dla zaproponowanego modelu przeprowadzono analizę wrażliwości wyjścia obiektu na zmianę parametrów.

Drugą część tego rozdziału poświęcono adaptacyjnemu algorytmowi podejmowania decyzji. Opisane zostały zadania dla trzech różnych przypadków tj.:

- z ustalonym z góry czasem zakończenia;
- z niejawnie zadanym czasem zakończenia;
- z rozmytym czasem zakończenia.

Zaproponowany został adaptacyjny algorytm podejmowania decyzji bazujący na algorytmach rozpoznawania obrazów z wykorzystaniem wiedzy eksperta.

Ostatnie zadanie, które zostało opisane w tym rozdziale dotyczy formalnej analizy stabilności procesu wspomagania podejmowania decyzji dla opracowanych algorytmów.

Rozdział trzeci to opis eksperymentów, które zostały przeprowadzone w celu pozyskania danych potrzebnych do rozwiązania zadania identyfikacji na pierwszym stopniu. Przeprowadzono również analizę uzyskanych danych i ich przydatność w procesie diagnostyki obiektu.

W pierwszej części zawarto opis warunków w jakich przeprowadzone zostały badania praktyczne. W drugiej natomiast dokonano analizy uzyskanych wyników dla zadania identyfikacji na pierwszym stopniu. Przedyskutowano przydatność otrzymanych wyników w zadaniu diagnostyki. W tym celu wykorzystano algorytmy identyfikacji, które w rozdziale pierwszym zostały opracowane dla zaproponowanego modelu na pierwszym stopniu.

Rozdział czwarty zawiera wyniki badań symulacyjnych dla opracowanego środowiska, które posłużyło do oceny opracowanych algorytmów adaptacyjnego podejmowania decyzji opartych o procedury rozpoznawania obrazów z dokładnymi algorytmami bazującymi na predykcji z modelem.

Rozdział piąty to podsumowanie rezultatów pracy oraz przedstawienie możliwych kierunków rozwoju zaproponowanej metodyki tworzenia algorytmów wspomagania podejmowania decyzji z wykorzystaniem identyfikacji dwustopniowej.


Rozdział 2

Adaptacyjny system podejmowania decyzji z wykorzystaniem identyfikacji dwustopniowej


2.1 Problem wspomaganie podejmowania decyzji dla zadania planowania rehabilitacji – opis problemu

W pracy rozpatrzono zadanie planowania rehabilitacji osób spastycznych z wykorzystaniem elektroterapii. Opisany w podrozdziale 1.3 problem medyczny stał się inspiracją do zaproponowania struktury adaptacyjnego systemu wspomaganie podejmowania decyzji oraz metodyki tworzenia algorytmów w oparciu o dwustopniowy model obiektu.

Elektroterapia jest uznaną i z powodzeniem wykorzystywaną metodą w leczeniu spastyczności, która pozwala na zmniejszenie napięcia spastycznego przy jednoczesnej poprawie koordynacji ruchów [89]. W pracach dotyczących zagadnienia planowania rehabilitacji poprzez *elektrostymulację* podkreśla się wysoką skuteczność metody [101]. Oprócz wymienionych zalet metoda ta ma też swoje wady. Główną z nich jest problem takiego doboru scenariuszy impulsów pobudzających (Rysunek 2.1) by zmęczenie mięśni następowało możliwie najwolniej [56]. W pracach [55], [56], [68], [112] rozpatruje się problem doboru sposobu po-



Rysunek 2.1: Cztery przykładowe scenariusze pobudzania mięśni impulsami elektrycznymi



Rysunek 2.2: Dwie przykładowe sekwencje impulsów pobudzających złożone z pięciu dostępnych scenariuszy

budzania mięśni chorego tak, by wymienione powyżej niepożądane zjawiska nie wpływały w znaczący sposób na terapię.

Fizjoterapeuta, planujący rehabilitację, ma do dyspozycji urządzenie pozwalające na generowanie impulsów elektrycznych o różnej częstotliwości. Jego zadaniem jest ustalenie takiej kolejności pojawiania się pobudzeń (Rysunek 2.2) by zmęczenie mięśni było jak najmniejsze, zapewniając jednocześnie skuteczne leczenie. Warte podkreślenia jest to, że każda ustalona sekwencja scenariuszy jest odpowiednia tylko dla danego pacjenta. Prowadzi to do indywidualizacji rehabilitacji, a co za tym idzie, plan dla każdego pacjenta musi być przygotowywany z osobna.

Jednym ze sposobów doboru zestawu impulsów pobudzających jest wykorzystanie modelowania matematycznego. W wymienionych powyżej pracach dotyczących omawianego zagadnienia, takie podejście zostało zastosowane.

W niniejszej pracy opisane zostały podstawy teoretyczne adaptacyjnego sys-

temu z wykorzystaniem identyfikacji dwustopniowej, którego zadaniem jest wspomaganie pracy fizjoterapeuty. W opisywanym rozwiązaniu, przy wykorzystaniu zgromadzonych w bazie wiedzy informacji pochodzących od ekspertów, zaproponowano narzędzie wspomagające podejmowanie decyzji przez lekarza prowadzącego rehabilitację. W zaproponowanym systemie może wyróżnić dwa główne bloki [156]:

- blok wspomagania diagnostyki medycznej;
- blok wspomagania planowania terapii.

Opracowane na potrzeby omawianego systemu algorytmy (związane z blokiem wspomagania terapii) oraz pozyskane w wyniku badań eksperymentalnych wyniki badań diagnostycznych (blok wspomagania diagnostyki medycznej) wykorzystywane są w procesie wspomagania podejmowania decyzji. Zaproponowane rozwiązanie umożliwia również monitorowanie stanu zdrowia pacjenta jak również dostosowywanie się do zachodzących w nim zmian w trakcie trwania terapii.

2.2 Struktura adaptacyjnego systemu wspomagania podejmowania decyzji z wykorzystaniem identyfikacji dwustopniowej

Rozważmy pewien system z dynamicznym obiektem dwustopniowym (Rysunek 2.3) którego charakterystyka jest następująca:

$$y(k_1) = \Phi_1(y(k_1 - 1), u_1(k_1); \mathbf{a}_1(k_2)), \quad (2.1)$$

$$\mathbf{a}_1(k_2) = \Phi_2(\mathbf{a}_1(k_2 - 1), \pi(k_2); \mathbf{a}_2(k_2)), \quad (2.2)$$

gdzie:

$u_1(k_1) \in \mathcal{U}_1 \subseteq \mathcal{R}^{S_1}$ – sygnał wejściowy na pierwszym stopniu o S_1 składowych;

$\pi(k_2) \in \mathcal{N}$ – zbiór scenariuszy – drugi stopień;

$\mathbf{a}_1(k_2) \in \mathcal{A}_1 \subseteq \mathcal{R}^{R_1}$ – wektor parametrów na pierwszym stopniu o R_1 składowych;

$\mathbf{a}_2(k_2) \in \mathcal{A}_2 \subseteq \mathcal{R}^{R_2}$ – wektor parametrów na drugim stopniu o R_2 składowych;

$y(k_1) \in \mathcal{Y} \subseteq \mathcal{R}^L$ – sygnał wyjściowy na pierwszym stopniu o L składowych;

$\Phi_1 : \mathcal{R}^{S_1} \times \mathcal{R}^{R_1} \times \mathcal{R}^L \longrightarrow \mathcal{R}^L$;

$\Phi_2 : \mathcal{N} \times \mathcal{R}^{R_2} \times \mathcal{R}^{R_1} \longrightarrow \mathcal{R}^{R_1}$;

k_1 – numer taktu na pierwszym stopniu;

k_2 – numer taktu na drugim stopniu.

Załóżmy, że dysponujemy pewnym skończonym zbiorem \aleph dostępnych scenariuszy oznaczonych jako π . Zbiór ten ma następującą postać:

$$\aleph = \{\pi_1, \pi_2, \dots, \pi_H\}, \quad (2.3)$$

gdzie H oznacza liczbę wszystkich dostępnych scenariuszy.

Każdy z dostępnych elementów zbioru \aleph , które zostały zgromadzone w bazie wiedzy, składa się z pewnego zestawu instrukcji realizowanych przez urządzenie wykonawcze (Rysunek 2.3) w kolejnych krokach procesu wspomaganie podejmowania decyzji. Zbiór ten zdefiniowano poniżej:

$$U_2 = \{u_{21}, u_{22}, \dots, u_{2L}\}, \quad (2.4)$$

gdzie L jest liczbą wszystkich instrukcji. Biorąc pod uwagę (2.4) możemy zapisać, że w skład każdego scenariusza wchodzi określona liczba instrukcji:

$$\pi = \{u_{2l_1}, u_{2l_2}, \dots, u_{2l_M}\}, \quad (2.5)$$

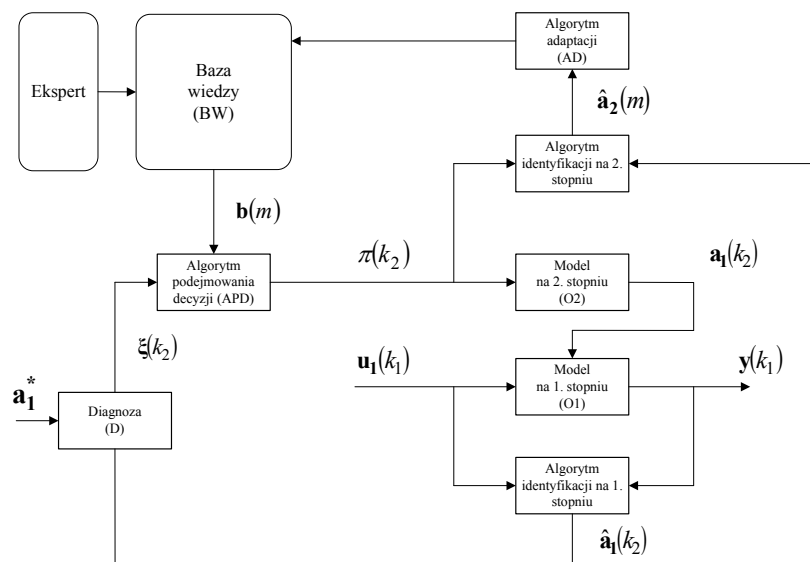
gdzie M jest liczbą instrukcji tworzących dany scenariusz.

Biorąc pod uwagę cechy układów identyfikacji systemów dwustopniowych oraz wykorzystując różnorodne struktury systemów wspomagających podejmowanie decyzji przedstawionych w podrozdziale 1.4 oraz m.in. w pracach [62], [160] zaproponowano pewien system adaptacyjnego wspomaganie podejmowania decyzji z wykorzystaniem identyfikacji dwustopniowej (Rysunek 2.3).

Na przedstawionym schemacie rozpatrywanego systemu (Rysunek 2.3), można wyróżnić kilka głównych elementów wchodzących w jego skład tj. dwustopniowy obiekt identyfikacji (oznaczony jako $O1$ oraz $O2$), algorytm wspomagający podejmowanie decyzji (APD), bazę wiedzy (BW), adaptator (AD) oraz urządzenie diagnozujące (D).

Głównym elementem w zaproponowanym systemie jest algorytm wspomagający proces podejmowania decyzji. Celem jego działania jest podjęcie takich działań lub ich sekwencji, które doprowadzą obiekt do pożądanego stanu. Stan ten charakteryzowany jest przez wewnętrzny zestaw parametrów $\mathbf{a}_1(k_2)$ zależności (2.1), którego bieżąca wartość jest wyznaczana w zadaniu identyfikacji na pierwszym z wyróżnionych stopni. Decyzje dotycząca kolejnych działań są podejmowane każdorazowo po zakończonej diagnozie obiektu na stopniu pomocniczym

[92]. Zadanie to wykonywane jest przez urządzenie diagnozujące i polega na porównaniu wartości wyznaczonego wektora parametrów $\mathbf{a}_1(k_2)$ na danym etapie procesu z jego wartością pożądaną \mathbf{a}_1^* .



Rysunek 2.3: Adaptacyjny system wspomagania podejmowania decyzji z identyfikacją dwustopniową i z wykorzystaniem wiedzy eksperta

Wykorzystane w zaproponowanym systemie podejście dwustopniowe (podrozdział 1.5) umożliwia ustalenie zależności pomiędzy wybranym scenariuszem a niemierzalnym bezpośrednio parametrem $\mathbf{a}_1(k_2)$ charakteryzującym aktualny stan obiektu. Wynik identyfikacji na drugim stopniu, czyli wartość wektora parametrów $\mathbf{a}_2(k_2)$ można wykorzystać do automatyzacji procesu wspomagania podejmowania decyzji [160].

Jedną z możliwych koncepcji, która została wykorzystana w zaproponowanym systemie, jest podejście ze strojeniem głównego algorytmu wspomagania podejmowania decyzji [42]. Oznacza to, że poprawa działania algorytmu następuje w kolejnych taktach strojenia poprzez zmianę wartości ustalonego wcześniej parametru głównego algorytmu wykorzystywanego w procesie wspomagania podejmowania decyzji. W tym celu w omawianym systemie wykorzystany został adaptator, który bazując na aktualnej wartości estymowanego wektora parametrów $\mathbf{a}_2(k_2)$ modyfikuje z pewnym taktom m wektor parametrów $\mathbf{b}(m)$ algorytmu wspomagania podejmowania decyzji (2.3).

Z wykorzystaniem powyższej procedury strojenia algorytmu podejmowania decyzji związane jest zwiększenie nakładów obliczeniowych. Jednakże koszty poniesione na pozyskanie dodatkowych danych powinny skutkować zwiększeniem efektywności procesu wspomaganie podejmowania decyzji, który mierzony jest pewnym ustalonym wskaźnikiem jakości Q^{pd} . Koncepcja wykorzystania adaptatora w zaproponowanym zadaniu usprawnia omawiany proces, ponieważ nie zawsze na etapie projektowania algorytmu możliwe jest dokładne wyznaczenie optymalnych wartości parametrów. Zwykle jest to związane z brakiem dokładnej informacji o obiekcie bądź z trudnym do przewidzenia zachowaniem obiektu w trakcie trwania procesu wspomaganie podejmowania decyzji. Wykorzystanie procedur adaptacyjnych pozwala na dobranie właściwej wartości parametru poprzez ocenę zachowania obiektu na podejmowane działania.

Opisany powyżej problem wspomaganie podejmowania decyzji może okazać się zadaniem trudnym, szczególnie dla obiektów o nieliniowych charakterystykach i zmiennych w czasie parametrach. Prowadzi to zwykle do skomplikowanego opisu matematycznego badanego procesu. W wielu przypadkach może to w sposób znaczący ograniczyć możliwe obszary zastosowań wyznaczonego modelu. Należy podkreślić, że dla wiele procesów czy też obiektów rzeczywistych trudno jest zaproponować jakikolwiek – nawet skomplikowany – opis matematyczny. W takich przypadkach, jedynym wyjściem jest wykorzystanie współczesnych metod, które w odróżnieniu od klasycznych koncepcji – znanych chociażby z teorii sterowania [6], [74], [85], [86] – nie wymagają formalnego opisu matematycznego procesu.

W pracy zaproponowano procedurę adaptacyjnego wspomaganie podejmowania decyzji w systemie dwustopniowym, która bazuje na algorytmach rozpoznawania obrazów [58], [94], [150]. Wykorzystanie powyższych procedur związane jest z zaproponowaną oryginalną metodą wspomaganie podejmowania decyzji z wykorzystaniem scenariuszy.

Warto podkreślić, że stosowanie algorytmów bazujących na procedurach rozpoznawania obiektów wiąże się ze stosunkowo szybkim czasem uzyskania rozwiązania w kolejnych krokach procesu wspomaganie podejmowania decyzji. Główną niedogodnością, z którą należy się liczyć wykorzystując algorytmy klasyfikacji obiektów, jest brak możliwości otrzymania dokładnego rozwiązania. Jednakże dla większości problemów rzeczywistych, przybliżone rozwiązanie nie jest znaczącym ograniczeniem a uzyskane wyniki mogą być zadowalające [53].

2.2.1 Model zespołu mięśni szkieletowych w stawie łokciowym – pierwszy stopień

Opis obiektu

W poniższym podpunkcie opisany został zespół mięśni szkieletowych w układzie ramię – przedramię. Głównym zadaniem, które ma spełniać zaproponowany model, jest umożliwienie przeprowadzenia diagnostyki mięśni kończyny górnej. Narzuca to pewne ograniczenia na sam model jak i sposób pozyskiwania danych eksperymentalnych.

Układ kostno-szkieletowy kończyny górnej jest układem bardzo skomplikowanym i próba dokładnego jego modelowania jest zadaniem trudnym. Przed rozpoczęciem analizy zależności pomiędzy daną grupą mięśni a ich wpływem na generowane siły należy przeanalizować proces pobudzania ich przez układ nerwowy.

Każdy z mięśni szkieletowych zbudowany jest z tysięcy włókien mięśniowych, które połączone są ze sobą tkanką łączną [119]. Generowanie przez mięśnie momentów sił jest możliwe jedynie podczas skurczów. Włókna mięśniowe są pobudzane do skurczów impulsami elektrycznymi, które generowane są przez układ nerwowy [119]. Opisany proces dokonuje się przez wykorzystanie specjalnych neuronów ruchowych, które nazywane są w literaturze *motoneuronami*. Aby możliwe było napędzanie układu ruchu, każdy mięsień na obu swych końcach przechodzi w ścięgna, które łączą go z układem kostnym [119]. Wartość siły, która jest generowana podczas skurczów mięśni zależy od trzech czynników: liczby pobudzanych jednostek motorycznych przez dany motoneuron, częstotliwości tych pobudzeń oraz ich synchroniczności [119]. Wszystkie te czynniki podlegają kontroli przez układ nerwowy i mają na celu generowanie sił o odpowiednich wartościach.

Mięśnie w organizmie pracują w zespołach. W omawianym problemie, analizie został poddany zespół mięśni szkieletowych łokcia. W rozważanym układzie kończyny górnej możemy wyróżnić dziewięć głównych mięśni szkieletowych: sześć zginaczy oraz trzy prostowniki [170], [171]. Zadaniem mięśni szkieletowych stawu łokciowego (oraz innych stawów) jest generowanie momentów sił. Na cały układ możemy spojrzeć jak na pewien system biomechaniczny, którego zadaniem jest przetwarzanie energii chemicznej na energię mechaniczną.

W kolejnym podpunkcie przedstawiono uproszczony model opisanego procesu, którego parametry w zaproponowanym systemie (2.3) wykorzystane są w

zadaniu diagnozowania obiektu.

Model obiektu

W literaturze dotyczącej modelowania ludzkiego układu ruchu możemy wyróżnić dwa podejścia. Pierwsze z nich to tzw. *proste zadanie dynamiki* (*ang. forward dynamics approach*). Charakteryzuje się ono tym, że trajektoria ruchu kończyny wyliczana jest na podstawie wyznaczonych wcześniej sił czynnych w zadanych grupach mięśni [171].

Drugie z podejść nazywane jest *odwrotnym zadaniem dynamiki* (*ang. inverse dynamics approach*). W metodzie tej zadana zostaje pewna trajektoria ruchu. Znając jej kształt, można wyznaczyć wartości sił jakie muszą zostać wygenerowane przez zadaną grupę mięśni by możliwe było osiągnięcie zamierzonego celu [128].

W niniejszej pracy wykorzystany będzie model, który zbudowane zostały zgodnie z pierwszym z wymienionych podejść. W pracy opisano a następnie wykorzystano w zadaniu identyfikacji model, który został opisany w pracach [107], [108], [113], [114] oraz [115].


Proces modelowania zachowania się mięśni szkieletowych podczas skurczów jest zadaniem bardzo skomplikowanym. Trudności wynikają głównie z tego, że jest to obiekt o nieliniowej charakterystyce oraz zmiennych w czasie parametrach. Dodatkowe problemy mogą wynikać z procesów zachodzących w mięśniach oraz z interakcji pomiędzy danymi grupami mięśni. Należy również pamiętać, że mięśnie szkieletowe sterowane są poprzez układ nerwowy. Ważne jest również to, by zmierzone sygnały miały wartość diagnostyczną tj. na ich kształt wpływ miały uszkodzenia charakterystyczne dla spastyczności.

Powyższe warunki spełnia przedstawiony powyżej model zaproponowany przez T.S. Buchanana i jego współpracowników [43]. Zależność ta opisuje relacje pomiędzy sygnałem przesyłanym przez układ nerwowy do odpowiednich mięśni (traktowanym jako sygnał wejściowy) a generowanym w danym stawie momentem siły (sygnał wyjściowy). Zarówno na jeden jak i drugi sygnał wpływ mają zmiany patologiczne związane ze spastycznością [146]. Pomiar momentu siły dokonywany jest bezpośrednio przy wykorzystaniu odpowiedniego urządzenia. Natomiast pomiar sygnałów pobudzających mięśnie następuje z większą trudnością i dokonuje się go pośrednio tzn. jest wyznaczany na podstawie pomiarów sygnałów

EMG. Sygnał EMG jest obrazem elektrycznej aktywności mięśni i mierzony jest w starannie dobranych miejscach na powierzchni skóry. Bazując na badaniach eksperymentalnych autorzy wymienionych prac, zaproponowali pewien model w postaci zestawu równań różnicowych [43].

Powyżej wspomniano, że do pośredniego wyznaczania sygnałów sterujących pobudzających mięśnie szkieletowe wykorzystano sygnały EMG. Powodów podjęcia takiej decyzji można podać kilka. Wśród tych najważniejszych należy wymienić bardzo łatwy pomiar sygnałów oraz nieinwazyjność metody (istnieją również sposoby inwazyjne z wykorzystaniem elektrod wkłuwanych). Powyższe cechy nie są bez znaczenia w praktycznych zastosowaniach, gdzie należy brać pod uwagę zarówno komfort badanego podczas testów jak i koszty ich wykonania.

Wybierając nieinwazyjną metodę pomiarów aktywności mięśni należy liczyć się z tym, że zdobyte dane będą silnie zaszumione. Wówczas, tak jak to zostało podkreślone w pracy [43], dane przed wykorzystaniem ich w zadaniu identyfikacji muszą zostać odpowiednio przygotowane. Opisane problemy są konsekwencją wykorzystania nieinwazyjnych metod pomiarowych. Ceną za niski koszt pomiaru i bezpieczeństwo pacjentów są zaszumione dane pomiarowe, które należy przygotować przed wykorzystaniem w kolejnych etapach. Na (Rysunek 2.4) przedstawiono sekwencję kolejnych zadań do wykonania, przed przystąpieniem do rozwiązania zadania estymacji. Pierwszym krokiem jest operacja prostowania dwupołówko-



Rysunek 2.4: Schemat kolejnych etapów przetwarzania sygnałów EMG

wego, w wyniku której otrzymamy sygnał EMG o nieujemnej amplitudzie. Po przeprowadzeniu powyższej operacji, kolejnym etapem jest odfiltrowanie zakłóceń pomiarowych. Operacja ta jest częścią procesu, który ma na celu przetworzenie zakłóconego sygnału pomiarowego (Rysunek 2.4). W literaturze zaleca się stosowanie filtrów Butterwortha [115].

Dysponując przetworzonym sygnałem pomiarowym EMG, kolejnym krokiem jest uformowanie sygnału zbliżonego do tego, jaki generowany jest przez układ nerwowy do pobudzania mięśni szkieletowych. W tym przypadku do ustalenie od-

powiedniej zależności wykorzystano badania eksperymentalne, co zostało opisane w min. pracach [43], [114].


W pracy [43] zaproponowano model, który w dalszej części pracy oznaczono: $\Phi_1(\cdot, \cdot; \cdot)$. Poszczególne elementy omawianej zależności zostały przedstawione poniżej. Pierwszy z nich – równanie stanu obiektu – ma postać:

$$x(k_1) = a_1^{(1)}(k_2)u_1(k_1 - d) - a_1^{(2)}(k_2)x(k_1 - 1) - a_1^{(3)}(k_2)x(k_1 - 2), \quad (2.6)$$

którego zadaniem jest formowanie sygnału zbliżonego kształtem do sygnału generowanego przez *motoneurony* podczas pobudzania mięśni szkieletowych.

W powyższym równaniu aktualna wartość zmiennej stanu $x(k_1)$ zależy od sygnału pobudzającego $u_1(k_1 - d)$ w chwili (k_1) oraz od wartości tego parametru w chwilach poprzednich. Parametr d jest interpretowany jako *opóźnienie neuromechaniczne* (*ang. neuromechanical delay*). W rzeczywistości parametr ten przyjmuje wartości z zakresu od 10 do 100 ms [51]. W pracy założono, że wartość opóźnienia równa jest 0 i nie jest brana pod uwagę w procesie identyfikacji.

Drugi człon w rozpatrywanym modelu jest członem nieliniowym i jego zadaniem jest przekształcenie wyznaczonego sygnału $x(k_1)$. Odpowiednia zależność (2.5) została wyznaczona na podstawie przeprowadzonych badań eksperymentalnych. Szczegółowy opis przeprowadzonych badań został zawarty w pracy [114]. Poniżej przedstawiono empiryczną krzywą ilustrującą zależność pomiędzy sygnałem generowanym przez *motoneurony* $x(k_1)$ a reakcją poszczególnych mięśni na to pobudzenie $y(k_1)$ [114] w postaci wygenerowanego momentu siły. W oparciu o



Rysunek 2.5: Zależność pomiędzy pobudzeniem mięśnia przez motoneurony a jego odpowiedzią na to pobudzenie

przeprowadzone badania [114] zaproponowano następującą zależność – równanie wyjścia obiektu:

$$\bar{y}(k_1) = \frac{e^{a_1^{(4)}(k_2)x(k_1)} - 1}{e^{a_1^{(4)}(k_2)} - 1}, \quad (2.7)$$

gdzie $a_1^{(4)}(k_2)$ jest pewnym współczynnikiem.

Ostatecznie otrzymano model, który opisuje zależność pomiędzy sygnałami pobudzającymi generowanymi przez motoneurony, a reakcją mięśni na to pobudzenie:

$$x(k_1) = a_1^{(1)}(k_2)u_1(k_1 - d) - a_1^{(2)}(k_2)x(k_1 - 1) - a_1^{(3)}(k_2)x(k_1 - 2) \quad (2.8)$$

$$\bar{y}(k_1) = \frac{e^{a_1^{(4)}(k_2)x(k_1)} - 1}{e^{a_1^{(4)}(k_2)} - 1},$$

gdzie:

$u_1(k_1)$ – sygnał wejściowy obiektu na pierwszym stopniu – przetworzony sygnał pomiarowy EMG;

$\bar{y}(k_1)$ – wyjście obiektu na pierwszym stopniu – moment siły generowany dla *MN* mięśni;

$a_1^{(1)}(k_2)$ – współczynnik skali;

$a_1^{(2)}(k_2)$, $a_1^{(3)}(k_2)$, $a_1^{(4)}(k_2)$ – współczynniki;

d – opóźnienie *neuromechaniczne*.

Warto podkreślić, że rozpatrywany proces jest niestacjonarny co związane jest min. z męceniem się mięśni przy długotrwałym wysiłku. Powyższą zależność należy wziąć pod uwagę zarówno podczas planowania eksperymentu jak i przy wyznaczaniu parametrów modelu na podstawie danych pomiarowych.

2.2.2 Analiza wrażliwości modelu zespołu mięśni szkieletowych w stawie łokciowym

W poprzednim podpunkcie zaproponowano model obiektu opisującego zależność pomiędzy sygnałami generowanymi przez *motoneurony* do pobudzania mięśni szkieletowych, a wytworzonym w wyniku tego – przez kończynę górną – *momentem siły*. We wcześniejszych częściach pracy zaznaczono, że estymowane para-

metry zaproponowanego modelu wykorzystane będą w zadaniu diagnostyki tj. zostaną tak dobrane, by mogły pełnić funkcję wskaźników diagnostycznych.

Wyboru modelu, który zostanie wykorzystany na pierwszym ze stopni, dokonano bazując na wynikach przeprowadzonych studiów literaturowych. Należy podkreślić, że w większości przypadków dotyczących modeli obiektów rzeczywistych zwykle zaproponowany opis jest pewnym kompromisem pomiędzy wymaganą dokładnością a nakładem pracy potrzebnym do jego zidentyfikowania [159]. Również i w omawianym przypadku mamy do czynienia z taką sytuacją. Zaproponowany model (2.8) zespołu mięśni szkieletowych jest modelem uproszczonym. Spowodowane jest to przede wszystkim tym, że analizowane zjawisko jest bardzo skomplikowane a jego opisanie za pomocą równań matematycznych jest zadaniem trudnym. Z drugiej strony tworzenie bardzo skomplikowanych modeli, w pewnych zastosowaniach nie jest pożądane. Rozbudowane modele mogą utrudniać analizę zachodzących zjawisk bądź, jak w omawianym zagadnieniu, w znacznym stopniu skomplikować proces wspomaganie podejmowania decyzji. Jak wspomniano wcześniej, model zespołu mięśni pełni funkcję pomocniczą tj. wartości estymowanych parametrów modelu są pewnego rodzaju wskaźnikami aktualnego stanu zdrowia pacjenta.

Pamiętając o powyższej uwadze, ważnym okazuje się przeprowadzenie analizy, która pozwoli określić zarówno przydatność diagnostyczną każdego z czterech parametrów zaproponowanej zależności (2.8) jak i ich wpływu na podejmowane decyzje. W podpunkcie tym dokonano analizy wrażliwości wyznaczonego modelu względem wektora parametrów $\mathbf{a}_1(k_2)$ [159].

Powyższa analiza, pozwala odpowiedzieć na kilka ważnych pytań. Problemy, które należy rozważyć związane są ze zróżnicowaniem populacji pacjentów a co za tym idzie ze zróżnicowaniem danych eksperymentalnych. Kolejnym utrudnieniem może okazać się brak możliwości przeprowadzenia badań w dokładnie takich samych warunkach. Powyższe kwestie muszą zostać wzięte pod uwagę przed dokonaniem wyboru, nie tylko odnośnie samego modelu ale również jego parametrów, które to zostaną wzięte pod uwagę w procesie wspomaganie podejmowania decyzji.

Proponując model do opisu pewnego zjawiska, procesu lub obiektu, który w proponowanym systemie ma pełnić funkcję diagnostyczną, szczególnie ważna jest odpowiedź na pytanie: jak zmienia się sygnał wyjściowy modelu w przy zmianie parametrów modelu? [148].

Odpowiedź na powyższe pytanie udziela analiza wrażliwości [159], która pozwala na oszacowanie przyrostów zmiennych opisujących model spowodowanych zmianami parametrów modelu [148].

Przyjęto następujące oznaczenia:

$\bar{y}(k_1, \mathbf{a}_1(k_2))$ – wyjście modelu, rozwiązanie równania modelu (2.8);

$\mathbf{a}_1(k_2)$ – wektor wartości parametrów modelu (2.8);

$\Delta \mathbf{a}_2$ – przyrost wektora wartości parametrów;

$\Delta \bar{y}(k_1, \mathbf{a}_2(k_2), \Delta \mathbf{a}_2)$ – zmiana wyjścia modelu odpowiadająca przyrostowi tj.

$$\Delta \bar{y}(k_1, \mathbf{a}_1(k_2), \Delta \mathbf{a}_1) = \bar{y}(k_1, \mathbf{a}_1(k_2) + \Delta \mathbf{a}_1) - \bar{y}(k_1, \mathbf{a}_1(k_2)).$$

Zadanie jest następujące: zbadać zależności pomiędzy $\Delta \bar{y}(k_1, \mathbf{a}_1(k_2), \Delta \mathbf{a}_1)$ oraz $\Delta \mathbf{a}_1$. W tym wypadku można posłużyć się następującą miarą tej zależności [148]:

$$\frac{\Delta \bar{y}(k_1, \mathbf{a}_1(k_2), \Delta \mathbf{a}_1)}{\Delta \mathbf{a}_1} = \frac{\bar{y}(k_1, \mathbf{a}_1(k_2) + \Delta \mathbf{a}_1) - \bar{y}(k_1, \mathbf{a}_1(k_2))}{\Delta \mathbf{a}_1}. \quad (2.9)$$

Dla $\Delta \mathbf{a}_1 \rightarrow 0$ mamy:

$$\frac{\Delta \bar{y}(k_1, \mathbf{a}_1(k_2), \Delta \mathbf{a}_1)}{\Delta \mathbf{a}_1} \rightarrow \frac{\partial}{\partial \mathbf{a}_1} \bar{y}(k_1, \mathbf{a}_1(k_2)) = \mathcal{S}(k_1, \mathbf{a}_1(k_2)), \quad (2.10)$$

gdzie funkcja $\mathcal{S}(k_1, \mathbf{a}_1(k_2))$ jest miarą wrażliwości sygnału $\bar{y}(k_1, \mathbf{a}_1(k_2))$. Dla małych $\Delta \mathbf{a}_1$ możemy zapisać:

$$\begin{aligned} \bar{y}(k_1, \mathbf{a}_1(k_2), \mathbf{a}_1(k_2) + \Delta \mathbf{a}_1) &\approx \\ &\approx \bar{y}(k_1, \mathbf{a}_1(k_2), \mathbf{a}_1(k_2)) + \Delta \mathbf{a}_1 \mathcal{S}(k_1, \mathbf{a}_1(k_2)). \end{aligned} \quad (2.11)$$

Badanie wrażliwości sprowadza się do badania funkcji $\mathcal{S}(k_1, \mathbf{a}_1(k_2))$ dla wyjścia modelu przy zmianach parametrów [148].

Wyjście zaproponowanego modelu (2.8) jest zależne od wektora parametrów $\mathbf{a}_1(k_2) = [a_1^{(1)} \ a_1^{(2)} \ a_1^{(3)} \ a_1^{(4)}]^T$. Różniczkując rozwiązane równania (2.8) kolejno po parametrach $a_1^{(i)}$, $i = 1, \dots, 4$ otrzymamy szukaną funkcję wrażliwości $\mathcal{S}(k_1, \mathbf{a}_1(k_2))$.

Niech: $\mathcal{S}_{\mathbf{a}_1}(k_1)$ będzie funkcją wrażliwości $\bar{y}(k_1, \mathbf{a}_1(k_2))$ wektora parametrów $\mathbf{a}_1(k_2)$:

$$\mathcal{S}_{\mathbf{a}_1}(k_1) = \frac{\partial}{\partial \mathbf{a}_1(k_2)} \bar{y}(k_1, \mathbf{a}_1(k_2)). \quad (2.12)$$

Różniczkując równanie (2.8) kolejno po parametrach $a_1^{(i)}$, $i = 1, \dots, 4$ otrzymujemy:

$$\mathcal{S}_{a_1^{(1)}}(k_1) = \frac{\partial \bar{y}(k_1, \mathbf{a}_1(k_2))}{\partial a_1^{(1)}} = \frac{a_1^{(4)}(k_2)}{e^{a_1^{(4)}(k_2)} - 1} \cdot u_1(k_1) \cdot e^{a_1^{(4)}(k_2)x(k_1)}, \quad (2.13)$$

$$\mathcal{S}_{a_1^{(2)}}(k_1) = \frac{\partial \bar{y}(k_1, \mathbf{a}_1(k_2))}{\partial a_1^{(2)}} = \frac{a_1^{(4)}(k_2)}{e^{a_1^{(4)}(k_2)} - 1} \cdot x(k_1 - 1) \cdot e^{a_1^{(4)}(k_2)x(k_1)}, \quad (2.14)$$

$$\mathcal{S}_{a_1^{(3)}}(k_1) = \frac{\partial \bar{y}(k_1, \mathbf{a}_1(k_2))}{\partial a_1^{(3)}} = \frac{a_1^{(4)}}{e^{a_1^{(4)}(k_2)} - 1} \cdot x(k_1 - 2) \cdot e^{a_1^{(4)}(k_2)x(k_1)}, \quad (2.15)$$

$$\mathcal{S}_{a_1^{(4)}}(k_1) = \frac{\partial \bar{y}(k_1, \mathbf{a}_1(k_2))}{\partial a_1^{(4)}} = \frac{1}{e^{a_1^{(4)}(k_2)} - 1} \cdot x(k_1) \cdot e^{a_1^{(4)}(k_2)x(k_1)}. \quad (2.16)$$

Jak wspomniano na początku tego podpunktu analiza wpływu zmiany danego parametru na model, może zostać wykorzystana do wyboru tylko tych elementów modelu, które będą miały wartość diagnostyczną. Przedstawione powyżej równania, zostaną wykorzystane w rozdziale (3) do oceny przydatności diagnostycznej poszczególnych parametrów modelu.

2.2.3 Identyfikacja modelu zespołu mięśni szkieletowych w stawie łokciowym – pierwszy stopień

W poniższym podpunkcie sformułowany został problem identyfikacji parametrów zaproponowanego modelu układu neuromięśniowego (2.8) na pierwszym stopniu adaptacyjnego systemu wspomagający podejmowanie decyzji (Rysunek 2.3).

Opis sygnałów pomiarowych

Przy ustalonym wejściu na stopniu drugim tj. scenariuszu $\pi(k_2)$, w wyniku identyfikacji na pierwszym stopniu, zgromadzono zestaw danych pomiarowych zapisanych w postaci:

$$U_{1N_1, k_2} = \{u_{1k_2}(k_1)\}_{k_1=1}^{N_1}, \quad (2.17)$$

$$Y_{N_1, k_2} = \{y_{k_2}(k_1)\}_{k_1=1}^{N_1}, \quad (2.18)$$

gdzie: N_1 jest liczbę powtórzeń eksperymentu na pierwszym stopniu dla k_2 -tego taktu na stopniu drugim.

Biorąc pod uwagę model na 1. stopniu zaproponujemy wskaźnik jakości postaci:

$$Q_1(\mathbf{a}_{1N_1}(k_2), \pi(k_2)) = \sum_{k_1=1}^{N_1} q_1\left(y_{k_2}(k_1), \Phi_1(\bar{y}(k_1-1), u_{1k_2}(k_1); \mathbf{a}_{1N_1}(k_2))\right), \quad (2.19)$$

gdzie $\Phi_1(\cdot, \cdot; \cdot)$ jest modelem procesu na pierwszym stopniu opisanego zależnością (2.8). Natomiast $q_1(\cdot, \cdot)$ to funkcja, której wartość porównuje wyjście obiektu i modelu na pierwszym stopniu. Poszukiwanie optymalnej wartości wektora parametrów:

$$\mathbf{a}_{1N_1}(k_2) = [a_1^{(1)} \quad a_1^{(2)} \quad a_1^{(3)} \quad a_1^{(4)}]^T,$$

sprowadza się do zadania minimalizacji wskaźnika jakości $Q_1(\mathbf{a}_{1N_1}(k_2), \pi(k_2))$:

$$Q_1(\hat{\mathbf{a}}_{1N_1}(k_2), \pi(k_2)) = \min_{\mathbf{a}_{1N_1}(k_2) \in \mathcal{A}_1} Q_1(\mathbf{a}_{1N_1}(k_2), \pi(k_2)), \quad (2.20)$$

Wynikiem minimalizacji powyższego wskaźnika $Q_1(\mathbf{a}_{1N_1}(k_2), \pi(k_2))$ jest algorytm identyfikacji na pierwszym stopniu:

$$\hat{\mathbf{a}}_{1N_1}(k_2) = \Psi_{1N_1}(U_{1N_1, k_2}, Y_{N_1, k_2}). \quad (2.21)$$

Powtarzając eksperyment identyfikacyjny na 1. stopniu dla różnych wartości wejścia na drugim stopniu tj. $\mathbf{\Pi}_{N_2} = \{\pi(k_2)\}_{k_2=1}^{N_2}$ uzyskujemy następującą sekwencję:

$$\hat{\mathbf{A}}_{1N_1, N_2} = \{\hat{\mathbf{a}}_{1N_1}(k_2)\}_{k_2=1}^{N_2}. \quad (2.22)$$

2.2.4 Sformułowanie zadania identyfikacji modelu

Dysponując danymi pomiarowymi, które zostały opisane w podpunkcie 2.2.3 możemy zaproponować algorytm identyfikacji parametrów modelu [60], [78], [110], [120], [142], [158] obiektu na pierwszym stopniu (2.8), którego ogólną postać przedstawiono poniżej:

$$\hat{\mathbf{a}}_{1N_1}^{(l+1)}(k_2) = \hat{\mathbf{a}}_{1N_1}^{(l)}(k_2) - \eta^{(l)} \nabla_{\mathbf{a}_1} Q_1(\mathbf{a}_1(k_2), \pi(k_2)) \Big|_{\mathbf{a}_1(k_2) = \hat{\mathbf{a}}_{1N_1}^{(l)}(k_2)}, \quad (2.23)$$

gdzie l jest kolejną iteracją, natomiast η jest pewnym, ustalonym współczynnikiem korekcji.

Chcąc wykorzystać powyższą zależność iteracyjną do poszukiwania optymalnego wektora parametrów $\mathbf{a}_{1N_1}(k_2)$ należy wyznaczyć gradient [11], [75] wskaźnika jakości $Q_1(\mathbf{a}_{1N_1}(k_2), \pi(k_2))$ po tych parametrach. Dla kwadratowego wskaźnika

jakości formuła przyjmuje następującą postać:

$$\begin{aligned}
 \nabla_{\mathbf{a}_1} Q_1(\mathbf{a}_{1N_1}(k_2), \pi(k_2)) &= \\
 &= - \sum_{k_1=1}^{N_1} q_1 \left(y_{k_2}(k_1), \Phi_1(\bar{y}(k_1-1), u_{1k_2}(k_1); \mathbf{a}_{1N_1}(k_2)) \right) \\
 &\quad \nabla_{\mathbf{a}_1} \Phi_1(\bar{y}(k_1-1), u_{1k_2}(k_1); \mathbf{a}_{1N_1}(k_2)). \tag{2.24}
 \end{aligned}$$

2.2.5 Algorytm identyfikacji

W poprzednim podpunkcie przedstawiono ogólny schemat algorytmu identyfikacji. W poniższym przedstawiono zestaw odpowiednich formuł.

Do iteracyjnego poszukiwania optymalnego wektora parametrów potrzebna jest znajomość pochodnych wskaźnika jakości po wszystkich składowych wektora parametrów tj. $a_1^{(i)}$, $i = 1, \dots, 4$. Poniżej przedstawiono zestaw czterech zależności:

$$\frac{\partial \bar{y}_{k_2}(k_1)}{\partial a_1^{(1)}} = \sum_{k_1=1}^{N_1} a_1^{(4)}(k_2) \cdot u_{1k_2}(k_1) \cdot \mathcal{C} \tag{2.25}$$

$$\frac{\partial \bar{y}_{k_2}(k_1)}{\partial a_1^{(2)}} = \sum_{k_1=1}^{N_1} a_1^{(4)}(k_2) \cdot x_{k_2}(k_1-1) \cdot \mathcal{C} \tag{2.26}$$

$$\frac{\partial \bar{y}_{k_2}(k_1)}{\partial a_1^{(3)}} = \sum_{k_1=1}^{N_1} a_1^{(4)}(k_2) \cdot u_{1k_2}(k_1-2) \cdot \mathcal{C} \tag{2.27}$$

$$\frac{\partial \bar{y}_{k_2}(k_1)}{\partial a_1^{(4)}} = \sum_{k_1=1}^{N_1} \left(x_{k_2}(k_1) - e^{a_1^{(4)}(k_2)} \right) \cdot \mathcal{C} \tag{2.28}$$

gdzie:

$$\mathcal{C} = \frac{e^{a_1^{(4)}(k_2)} (a_1^{(1)}(k_2) u_{1k_2}(k_1) - a_1^{(2)}(k_2) x_{k_2}(k_1-1) - a_1^{(3)}(k_2) x_{k_2}(k_1-2))}{e^{a_1^{(4)}(k_2)} - 1}. \tag{2.29}$$

2.2.6 Model wpływu procesu podejmowania decyzji na zmianę parametrów obiektu – drugi stopień

Opis procesu

Opisany w podpunkcie 2.2.1 model zespołu mięśni szkieletowych w stawie łokciowym oraz proces identyfikacji jego parametrów w podpunkcie 2.2.3 pełni w zaproponowanym systemie adaptacyjnego podejmowania decyzji (2.3) funkcję pomocniczą tj. pozyskane w wyniku eksperymentu identyfikacyjnego dane

oraz estymowane na ich podstawie parametry zależności (2.8) wykorzystuje się w celach diagnostycznych. Głównym zadaniem jest ustalenie zależności pomiędzy sekwencją scenariuszy a ich wpływem na pewien niemierzalny bezpośrednio parametr rozpatrywanego obiektu na stopniu pierwszym.

Znając zależność pomiędzy sekwencją scenariuszy a pewnym parametrem charakteryzującym obiekt na pierwszym stopniu, można zaproponować algorytm strojenia (podrozdział 2.3.7) procedury podejmowania decyzji ψ^{pd} . Na (Rysunek 2.3) został zaznaczony blok adaptatora, który wykorzystując informację o bieżącej wartości wektora parametrów $\mathbf{a}_2(k_2)$ dokonuje modyfikacji parametrów algorytmu podejmowania decyzji [160]. Wspomniana procedura zostanie szczegółowo omówiona w podpunkcie 2.3.3. W wyniku opisanych powyżej zmian otrzymamy nową procedurę nazwaną adaptacyjnym algorytmem podejmowania decyzji.

Model procesu

W poniższym podpunkcie zaproponowano oraz dokonano analizy pewnego modelu procesu na drugim stopniu w omawianym adaptacyjnym systemie wspomaganego podejmowania decyzji (2.3).

Na omawianym stopniu, w rozpatrywanym zadaniu, opisana jest zależność pomiędzy sekwencją scenariuszy a ich wpływem na wartość wektora parametrów charakteryzujących obiekt na pierwszym stopniu. Ponieważ nie istnieją modele dla opisanego procesu, koniecznym staje się wykorzystanie uniwersalnych metod opisu zależności pomiędzy sygnałami wejściowymi a wyjściowymi na drugim z rozpatrywanych stopni.

W podrozdziale przedstawiono model obiektu na drugim stopniu w postaci zestawu reguł, gdzie następniki – zgodnie z założeniami modelu *Takagi-Sugeno* – mają postać funkcyjną:

$$\mathcal{R}_2^{(r_m)} : \text{ JEŻELI } \pi(k_2) \text{ jest } \mathcal{D}^{(r_m)} \text{ TO} \\ \mathfrak{a}_{1N_1}^{(r_m)}(k_2 + 1) = f^{(r_m)} \left(\sum_{i=1}^{d_\pi} \left(\mathbf{a}_2^{(i)} \right)^{(r_m)} \pi(k_2 - i) \right), \quad (2.30)$$

gdzie $r_m = 1, \dots, R_m$ jest liczbą reguł w bazie, $\mathcal{D}^{(r_2)}$ to wartość lingwistyczna przesłanki dla r_m -tej reguły.

Natomiast wektor parametrów $\left(\mathbf{a}_2^{(i)} \right)^{(r_m)}$ ma postać:

$$\mathbf{A}_2^{(r_m)} = \left[\left(\mathbf{a}_2^{(1)} \right)^{(r_m)} \quad \left(\mathbf{a}_2^{(2)} \right)^{(r_m)} \quad \dots \quad \left(\mathbf{a}_2^{(d_\pi)} \right)^{(r_m)} \right]^T. \quad (2.31)$$

Tak jak pokazano powyżej, postać funkcji konkluzji może mieć – w ogólnej postaci – formę funkcji nieliniowej. W przeprowadzonych badaniach (rozdział 4) wykorzystano zarówno model *ARX* jak i *NARX*.

W celu otrzymania w pełni funkcjonalnego modelu z sygnałem wyjściowym, należy dokonać sumowania sygnałów pochodzących z poszczególnych wyjść $\mathbf{a}_{1N_1}^{(r_m)}(k_2)$. Do dalszych rozważań przyjęto gaussowski typ funkcji przynależności tj.

$$\vartheta^{(r_m)}\left(\pi(k_2); m^{(r_m)}, \sigma^{(r_m)}\right)$$

postaci:

$$\vartheta^{(r_m)}\left(\pi(k_2); m^{(r_m)}, \sigma^{(r_m)}\right) = \exp\left(-\frac{1}{2}\left(\frac{\pi(k_2) - m^{(r_m)}}{\sigma^{(r_m)}}\right)^2\right), \quad (2.32)$$

oraz regułą środka obszaru. Dla tak przyjętych danych wyjście modelu rozmytego przyjmuje postać:

$$\bar{\mathbf{a}}_{1N_1}(k_2 + 1) = \frac{\sum_{r_m=1}^{R_m} \exp\left(-\frac{1}{2}\left(\frac{\pi(k_2) - m^{(r_m)}}{\sigma^{(r_m)}}\right)^2\right) \mathbf{a}_{1N_1}^{(r_m)}(k_2 + 1)}{\sum_{r_m=1}^{R_m} \exp\left(-\frac{1}{2}\left(\frac{\pi(k_2) - m^{(r_m)}}{\sigma^{(r_m)}}\right)^2\right)}. \quad (2.33)$$

2.2.7 Identyfikacja modelu wpływu procesu podejmowania decyzji na zmianę parametrów obiektu – drugi stopień

Opis sygnałów pomiarowych

Zgromadzone w procesie wspomagania podejmowania decyzji dane zapisano w postaci:

$$\mathbf{\Pi}_{N_2} = \{\pi(k_2)\}_{k_2=1}^{N_2}, \quad (2.34)$$

$$\hat{\mathbf{A}}_{1N_1, N_2} = \{\hat{\mathbf{a}}_{1n_1}(k_2)\}_{k_2=1}^{N_2}. \quad (2.35)$$

gdzie N_1 określa liczbę powtórzeń eksperymentu na 1. stopniu, natomiast N_2 na drugim.

2.2.8 Sformułowanie zadania identyfikacji modelu

Wykorzystując dane eksperymentalne uzyskane w wyniku odpowiednio zaprojektowanego eksperymentu na drugim stopniu oraz poprzez minimalizację empirycz-

nego kryterium identyfikacji w postaci:

$$Q_2(\mathbf{a}_2(k_2)) = \sum_{k_2=1}^{N_2} q_2 \left(\hat{\mathbf{a}}_{1N_1}(k_2), \Phi_2(\bar{\mathbf{a}}_1(k_2 - 1), \pi(k_2); \mathbf{a}_2(k_2)) \right), \quad (2.36)$$

względem $\mathbf{a}_2(k_2)$:

$$Q_2(\mathbf{a}_2^*(k_2)) = \min_{\mathbf{a}_2(k_2) \in \mathcal{A}_1} Q_2(\mathbf{a}_2(k_2)), \quad (2.37)$$

otrzymujemy algorytm identyfikacji na drugim stopniu:

$$\hat{\mathbf{a}}_{2N_1, N_2} = \Psi_{2N_2}(\mathbf{\Pi}_{N_2}, \hat{\mathbf{A}}_{1N_1, N_2}), \quad (2.38)$$

gdzie $q_2(\cdot, \cdot)$ jest mierzalną funkcją, której wartość porównuje wyjście obiektu i modelu na drugim stopniu.

2.2.9 Algorytm identyfikacji

Podobnie jak w podpunkcie 2.2.4 również dla zadania identyfikacji na stopniu drugim wykorzystamy iteracyjny algorytm poszukiwania optymalnej wartości wektora parametrów $\mathbf{a}_2(k_2)$ postaci:

$$\hat{\mathbf{a}}_{2N_1, N_2}^{(l+1)} = \hat{\mathbf{a}}_{2N_1, N_2}^{(l)} - \eta^{(l)} \nabla_{\mathbf{a}_2} Q_2(\mathbf{a}_{2N_1, N_2}^{(l)})|_{\mathbf{a}_{2N_1, N_2} = \hat{\mathbf{a}}_{2N_1, N_2}^{(l)}}, \quad (2.39)$$

gdzie l jest kolejną iteracją, natomiast η jest współczynnikiem korekcji.

Dla kwadratowego wskaźnika jakości formuła przyjmuje postać:

$$\begin{aligned} \nabla_{\mathbf{a}_2} Q_2(\mathbf{a}_{2N_1, N_2}^{(l)}) = & - \sum_{k_2=1}^{N_2} \left(\hat{\mathbf{a}}_{1N_1}(k_2) - \Phi_2(\bar{\mathbf{a}}_1(k_2 - 1), \pi(k_2); \mathbf{a}_2(k_2)) \right) \\ & \nabla_{\mathbf{a}_2} \Phi_2(\bar{\mathbf{a}}_1(k_2 - 1), \pi(k_2); \mathbf{a}_2(k_2)). \end{aligned} \quad (2.40)$$

Zestaw odpowiednich zależności przedstawiono poniżej:

$$\frac{\partial \bar{\mathbf{a}}_{1N_1}^{(r_m)}(k_2)}{\partial (a_2^{(i)})^{(r_m)}} = \phi^{(r_m)}(k_2) \cdot \epsilon_{N_1}(k_2) \cdot \pi(k_2) \quad \text{gdzie } i \geq 1, \quad (2.41)$$

$$\begin{aligned} \frac{\partial \bar{\mathbf{a}}_{1N_1}^{(r_m)}(k_2)}{\partial m^{(r_m)}} = & \phi^{(r_m)}(k_2) \cdot \epsilon_{N_1}(k_2) \cdot \left(\bar{\mathbf{a}}_{1N_1}^{(r_2)}(k_2) + \right. \\ & \left. - \bar{\mathbf{a}}_{1N_1}^{(r_2)}(k_2) \right) \cdot \frac{\pi(k_2) - m^{(r_m)}}{(\sigma^{(r_m)})^2}, \end{aligned} \quad (2.42)$$

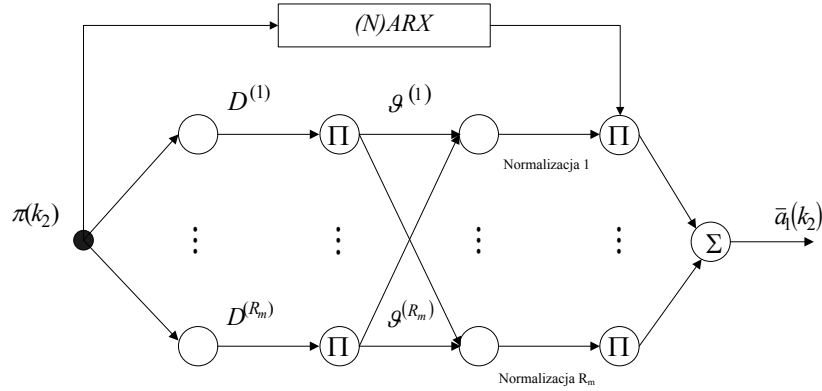
$$\begin{aligned} \frac{\partial \bar{\mathbf{a}}_{\mathbf{1}N_1}^{(r_m)}(k_2)}{\partial \sigma^{(r_m)}} &= \phi^{(r_m)}(k_2) \cdot \epsilon_{N_1}(k_2) \cdot \left(\mathbf{a}_{\mathbf{1}N_1}^{(r_m)}(k_2) + \right. \\ &\quad \left. - \bar{\mathbf{a}}_{\mathbf{1}N_1}^{(r_m)}(k_2) \right) \cdot \frac{\pi(k_2) - m^{(r_m)}}{\left(\sigma^{(r_m)} \right)^3}, \end{aligned} \quad (2.43)$$

gdzie:

$$\phi^{(r_m)}(k_2) = \frac{\vartheta^{(r_m)}(k_2)}{\sum_{j=1}^{R_m} \vartheta^{(j)}(k_2)}, \quad (2.44)$$

to unormowany poziom aktywacji. Natomiast $\epsilon_{n_1}(k_2)$ to:

$$\epsilon_{N_1}(k_2) = \bar{\mathbf{a}}_{\mathbf{1}N_1}^{(r_m)}(k_2) - \hat{\mathbf{a}}_{\mathbf{1}N_1}(k_2). \quad (2.45)$$



Rysunek 2.6: Struktura zaproponowanego systemu T - S (2.33)

2.3 Zadanie podejmowania decyzji

Opis zadania

Większość obiektów, które pojawiają się w rzeczywistych zadaniach to obiekty o nieliniowych charakterystykach. Dodatkowo, w przypadkach nietrywialnych, zwykle należy również wziąć pod uwagę niepewność, która może być związana np. z niemierzalnymi zakłóceniami pomiarowymi. Wymienione powyżej trudności powodują, że zaproponowanie ścisłego opisu matematycznego procesu może być zadaniem bardzo trudnym bądź niemożliwym.

W poniższym podpunkcie sformułowany został problem wieloetapowego wspomaganie podejmowania decyzji w odniesieniu do obiektu nieliniowego, w którym informacja zwrotna o aktualnym stanie obiektu jest zakłócona.

W pracy rozpatrywany jest problem wspomaganie podejmowania decyzji w odniesieniu do pewnego obiektu o nieliniowej charakterystyce i parametrach zmiennych w czasie (podrozdział 2.2.1). Przy projektowaniu systemu dla omawianego zadania należy wziąć również pod uwagę to, że pomiary wielkości wykorzystywanych do wyboru w kolejnych krokach odpowiedniego scenariusza są zakłócone. Zakłócenia te mogą być spowodowane np. sposobem dokonywania pomiarów czy też innymi czynnikami, nad którymi w trakcie eksperymentu nie ma się kontroli.

Na problemy związane z zadaniem wspomaganie podejmowania decyzji dla obiektów o nieliniowych charakterystykach w warunkach niepewnych zwrócono uwagę w [3], [5]. W wymienionych pracach autor dokonał wstępnego sformułowania problemu oraz podał możliwe kierunki rozwoju zaproponowanych metod [4], [5]. Jedną z nich, wymienionych w powyższych pracach, jest sterowanie adaptacyjne obiektami nieliniowymi z wykorzystaniem zakłóconych danych pomiarowych przy wykorzystaniu wiedzy eksperta. Problematykę tą poruszono również w [52], [53] oraz [36], [37], [38], [39], [40], [41], [42].

Projektowanie systemów wspomagających podejmowanie decyzji dla obiektów złożonych o nieliniowych charakterystykach z wykorzystaniem wiedzy eksperta może prowadzić do polepszenia wydajności rozpatrywanego systemu. Należy jednak pamiętać, że polepszenie pewnych własności (np. przyspieszenie procesu oraz zmniejszenie kosztów wspomaganie podejmowania decyzji) może skutkować pogorszeniem innych (np. jakością uzyskiwanych wyników). Nie jest to jednak cechą wykluczającą stosowanie w zadaniach praktycznych omawianego podejścia, ponieważ projektant systemu wspomagającego podejmowanie decyzji może dokonać wyboru i zaproponować zadowalające rozwiązanie, które spełni wymagania stawiane projektowanemu systemowi.

Koncepcja projektowania systemów wykorzystywanych w zadaniu wspomaganie podejmowania decyzji opartych na wiedzy eksperta ma, poza wymienionymi powyżej zaletami, również wady. Jedną z głównych, o której wspomniano min. w pracach [104], [106], jest problem z wyborem reprezentacji wiedzy w projektowanych systemach informatycznych.

Wykorzystywana wiedza może być deklaratywna lub proceduralna [139]. To,

który sposób zostanie wykorzystany w konkretnym zadaniu może zależeć min. od eksperta. Wpływ na decyzję może mieć również to, czy w projektowanym systemie ważna jest efektywność obliczeniowa, łatwość modyfikacji wiedzy zgromadzonej w bazie wiedzy itp.

W pracach [8], [83] podano przykłady, do rozwiązania których wykorzystano system bazujący na logice rozmytej. Natomiast w artykułach [9], [10] opisano problem wykorzystania podejścia bazującego na zbiorach reguł w procesie regulacji parametrów regulatora PID.

Wymienione powyżej metody projektowania algorytmów nie są jedynymi. W omawianej pracy do konstrukcji algorytmu podejmowania decyzji wykorzystano procedury rozpoznawania obiektów. Zastosowanie powyższych algorytmów w zadaniu rozpoznawania zostało zaproponowane przez E.H. Bristol [16], [137]. Wykorzystanie w zadaniu wspomaganie podejmowania decyzji algorytmów rozpoznawania pozwala na projektowanie systemów charakteryzujących się dużą odpornością na zakłócenia pomiarowe. Możliwe jest zaproponowanie takich algorytmów, które będą dostosowywać się do zmieniających się warunków w otoczeniu obiektu jak i do samego obiektu. Jest to bardzo ważne, ponieważ na etapie projektowania algorytmu nie jest możliwe dokładne określenie jak proces będzie przebiegał.

Przedstawiony schemat systemu z adaptacją charakteryzuje się strukturą warstwową. Każda z warstw pełni w takim systemie odmienną funkcję. Wśród najważniejszych możemy wyróżnić warstwę sterowania niskopoziomowego oraz warstwę optymalizacji [42], [62], [65], [67], [95], która jest wykorzystywana do poprawiania skuteczności działania algorytmu podstawowego tj. algorytmu podejmowania decyzji.

Zaletą algorytmów rozpoznawania obiektów jest to, że umożliwiają wykorzystanie w projektowanym systemie wiedzy eksperta. Pozwala to na łatwą implementację podejścia zaproponowanego w pracy [156], które polega na zastosowaniu danych zdobytych podczas obserwacji działań lekarza. Dysponując odpowiednim zbiorem danych z różnych procesów terapeutycznych system może naśladować zachowanie lekarza [156]. Warty podkreślenia jest fakt, że zaproponowany system informatyczny decyzyjnie podejmuje znacznie szybciej niż lekarz [156] jak również – co jest bardzo ważne – możliwe jest wyeliminowanie pomyłek.

Oprócz niewątpliwych korzyści wynikających ze stosowania w zadaniu wspomaganie podejmowania decyzji algorytmów rozpoznawania obrazów związane są również z nimi pewne niedogodności, które należy brać pod uwagę projektując

dany system. Wśród tych najważniejszych należy wymienić możliwość uzyskania jedynie przybliżonego rozwiązania oraz uzależnieniem uzyskanych wyników od wiedzy pochodzącej od eksperta. W rzeczywistych systemach rozwiązanie jest pewnym kompromisem pomiędzy kosztem, jaki należy ponieść by rozwiązać dane zadanie, a dokładnością uzyskanych wyników.

Zaproponowany algorytm podejmowania decyzji, wykorzystany w zadaniu ustalania pewnej sekwencji scenariuszy, wpisuje się w bardzo popularny i intensywnie eksplorowany obszar zastosowań sztucznej inteligencji w zadaniu wspomaganego podejmowania decyzji obiektami złożonymi.

Na przestrzeni ostatnich dekad zastosowano omawianą technikę w różnorodnych zadaniach biotechnicznych [66], [76], [90], czy też technicznych [15], [73], [135], [136], [141], [143], [163] oraz [174] gdzie wykorzystano omawianą metodologię w zadaniu sterowania ramieniem robota. Natomiast w pracy [81] przedstawiono wiele różnorodnych obszarów zastosowań omawianej metodologii.

Z dziedziny bliższej tej omawianej w pracy, a dotyczącej problemów medycyny można wymienić prace [50], [129], gdzie autorzy omówili teoretyczne aspekty związane z wykorzystaniem wiedzy eksperta. Wskazano również możliwe obszary zastosowań dla dyskutowanej metodologii.

Opis danych pomiarowych

Opisany w poniższym punkcie algorytm podejmowania decyzji wykorzystuje dane, które zgromadzono w procesie identyfikacji modelu układu mięśni szkieletowych (2.8) na pierwszym stopniu (podrozdział 2.2.3). Zaproponowana procedura w pierwszym kroku określa różnicę pomiędzy wartością żądaną wewnętrznego parametru modelu na pierwszym stopniu \mathbf{a}_1^* a jego bieżącą wartością $\hat{\mathbf{a}}_{1N_1}(k_2)$. Następny etap to – bazując na wartości wyznaczonej różnicy – wybór scenariusza, który powinien zostać zrealizowany w kolejnym kroku (Rysunek 2.3).

W podpunkcie (2.3.7) zaproponowano modyfikację głównego algorytmu podejmowania decyzji, który korzystając z danych uzyskanych w wyniku identyfikacji modelu na drugim stopniu dostraja algorytm w celu poprawienia wyników uzyskiwanych w procesie wspomaganego podejmowania decyzji.

2.3.1 Sformułowanie problemu wspomaganie podejmowania decyzji

Zdefiniujemy pewien system wspomaganie podejmowania decyzji, który charakteryzuje się skończoną przestrzenią stanów:

$$\mathbb{S} = \{s_1, s_2, \dots, s_F\}, \quad (2.46)$$

gdzie F jest liczbą wszystkich stanów.

Założmy również, że dysponujemy pewnym skończonym zbiorem dostępnych scenariuszy \aleph (2.3).

Niech istnieje pewne odwzorowanie takie, że $\Psi : \mathbb{S} \rightarrow \aleph$.

W kolejnych krokach podejmowana jest decyzja dotyczące numeru scenariusza $\pi(k_2)$ co w sposób jednoznaczny określa, jaką sekwencję sterującą $\{u_{2l_m}\}_{m=1}^M$ (2.5) należy przyłożyć do obiektu w k_2 -tej chwili.

To w jakim stanie (2.46) znajdzie się rozpatrywany system wspomaganie podejmowania decyzji w kroku $(k_2 + 1)$ zależy również od macierzy stochastycznej \mathbf{P} [65]. Macierz ta określa prawdopodobieństwa przejścia pomiędzy poszczególnymi stanami tj. osiągnięcie stanu w chwili $s(k_2 + 1) \in \mathbb{S}$, ze stanu na etapie $s(k_2) \in \mathbb{S}$.

Tak jak wspomniano powyżej, przejście z jednego stanu do drugiego wiąże się z podjętą decyzją dla rozpatrywanego obiektu. Wynika z tego, że dobierając odpowiednią sekwencję scenariuszy $\{\pi(k_2)\}_{k_2=1}^{K_2}$ możemy oddziaływać na niego w taki sposób, by możliwe stało się doprowadzenie go do pożądanego stanu.

Opisany powyżej system można wykorzystać w zadaniu wspomaganie podejmowania decyzji. Wśród najpopularniejszych sformułowań problemu można wskazać następujące podejścia:

- z ustalonym z góry czasem zakończenia;
- z niejawnie zadanym czasem zakończenia;
- z rozmytym czasem zakończenia.

zarówno dla obiektu deterministycznego jak i stochastycznego [84].

W omawianym procesie decyzje o wyborze kolejnych scenariuszy podejmowane są nie na podstawie aktualnej wartości wektora parametrów $\hat{\mathbf{a}}_{1N_1}(k_2)$ a różnicy pomiędzy wartością aktualną tego parametru a pożądaną (Rysunek 2.3) tj.:

$$\hat{\xi}(k_2) = q^{pd}(\mathbf{a}_1^*, \hat{\mathbf{a}}_{1N_1}(k_2)). \quad (2.47)$$

2.3.2 Algorytm wspomaganie podejmowania decyzji

W poniższym podpunkcie został rozpatrzony następujący problem: wyznaczyć taką sekwencję działań, która doprowadzi do pożądanego stanu pewien obiekt opisany zależnościami (2.8). Oczywiście, rozwiązując tak postawiony problem należy liczyć się z ograniczeniami i brać je pod uwagę. Nawiązując do problemu rozpatrywanego w pracy, można zadanie to przedstawić jako problem wyboru planu rehabilitacji dla pacjenta. Ograniczeniami w tym przypadku mogą być: czas, stopień upośledzenia osoby cierpiącej na spastyczność jak również doświadczenie fizjoterapeuty.

Problem planowania rehabilitacji można rozpatrywać jako zadanie wspomaganie wieloetapowego podejmowania decyzji [12], [84], [96] gdzie jako rozwiązanie otrzymujemy pewną sekwencję scenariuszy $\{\pi(k_2)\}_{k_2=1}^{K_2}$. Wygenerowany ciąg scenariuszy powinien umożliwić doprowadzenie rozpatrywanego obiektu od pewnego stanu początkowego do pożądanego stanu końcowego w skończonej liczbie kroków. Do oceny podjętych decyzji należy wykorzystać zdefiniowane wskaźniki jakości Q^{pd} (2.49, 2.51, 2.53, 2.55, 2.57, 2.59). Celem procesu decyzyjnego jest wybranie tej z możliwych sekwencji $\{\pi(k_2)\}_{k_2=1}^{K_2}$, która będzie minimalizować odpowiedni dla zadanego problemu wskaźnik jakości Q^{pd} .

Proces wspomaganie podejmowania decyzji dla obiektu deterministycznego z ustalonym z góry czasem zakończenia

Niech rozpatrywany obiekt będzie opisany zestawem równań (1.6) oraz (1.7). Na drugim stopniu wykorzystano algorytm wspomaganie podejmowania decyzji Ψ^{pd} , który wyznacza sekwencję decyzji $\{\pi(k_2)\}_{k_2=1}^{K_2}$ przyjmujących wartości ze zbioru \aleph . Niech czas zakończenia K_2 będzie znaną i zadaną z góry dodatnią liczbą całkowitą. Rozpatrzmy zadanie z początkowym $\hat{\mathbf{a}}_1(1)$ oraz końcowym $\hat{\mathbf{a}}_1(K_2)$ stanem obiektu.

Zadanie polega na znalezieniu optymalnego ciągu decyzji

$$(\pi^*(1), \pi^*(2), \dots, \pi^*(K_2 - 1)),$$

przy czym $\pi^*(k_2) \in \aleph$ dla każdego $k_2 = 0, 1, \dots, K_2$, tj.:

$$\begin{aligned} Q^{pd}(\pi^*(1), \pi^*(2), \dots, \pi^*(K_2 - 1); \hat{\xi}(1), \hat{\xi}(2), \dots, \hat{\xi}(K_2)) = \\ = \min_{\pi(1), \pi(2), \dots, \pi(K_2-1) \in \aleph} Q^{pd}(\pi(k_2), \hat{\xi}(k_2)), \end{aligned} \quad (2.48)$$


Dla następującego wskaźnika jakości $Q^{pd}(\cdot, \cdot)$:

$$\begin{aligned} Q^{pd}(\pi^*(1), \pi^*(2), \dots, \pi^*(K_2 - 1); \hat{\xi}(1), \hat{\xi}(2), \dots, \hat{\xi}(K_2)) &= \\ &= \sum_{k_2=1}^{K_2} q^{pd}(\pi(k_2), \hat{\xi}(k_2)), \end{aligned} \quad (2.49)$$

Proces wspomaganie podejmowania decyzji dla obiektu stochastycznego z ustalonym z góry czasem zakończenia

Również i w tym zadaniu czas zakończenia K_2 jest z góry znany i ustalony, ciąg decyzji $(\pi^*(1), \pi^*(2), \dots, \pi^*(K_2 - 1))$ jest również generowany przez algorytm wspomaganie podejmowania decyzji Ψ^{pd} . Różnica w stosunku do problemu przedstawionego we wcześniejszym podpunkcie jest taka, że pomiar wielkości $\hat{\xi}(k_2)$ jest obarczony pewnym błędem $\mathbf{z}(k_2)$ tj. $\tilde{\xi}(k_2) = g_z(\hat{\xi}(k_2), \mathbf{z}(k_2))$ (Rysunek 2.7), gdzie $\mathbf{z}(k_2) \in \mathcal{Z} \subseteq \mathcal{R}^{R_1}$. Opisany problem można przedstawić w postaci:

$$\begin{aligned} \mathbb{E} \left[Q^{pd}(\pi^*(1), \pi^*(2), \dots, \pi^*(K_2 - 1); \tilde{\xi}(1), \tilde{\xi}(2), \dots, \tilde{\xi}(K_2)) \right] &= \\ &= \min_{\pi(1), \pi(2), \dots, \pi(K_2 - 1) \in \mathbb{N}} \mathbb{E} \left[Q^{pd}(\pi(k_2), \tilde{\xi}(k_2)) \right], \end{aligned} \quad (2.50)$$



Rysunek 2.7: Pomiar wielkości $\mathbf{x}(k)$ z zakłóceniem $\mathbf{z}(k)$

Dla następującego wskaźnika jakości $Q^{pd}(\cdot, \cdot)$:

$$\begin{aligned} Q^{pd}(\pi^*(1), \pi^*(2), \dots, \pi^*(K_2 - 1); \tilde{\xi}(1), \tilde{\xi}(2), \dots, \tilde{\xi}(K_2)) &= \\ &= \sum_{k_2=1}^{K_2} q^{pd}(\pi(k_2), \tilde{\xi}(k_2)), \end{aligned} \quad (2.51)$$

Proces wspomagania podejmowania decyzji dla obiektu deterministycznego z niejawnie zadaniem czasem zakończenia

W wielu rzeczywistych procesach czas zakończenia jest niemożliwy do określenia, bądź jest nieistotny. Druga z sytuacji może mieć miejsce wówczas, gdy istotne jest samo osiągnięcie pewnego stanu a nie czas po jakim to nastąpiło. Taki problem określa się w literaturze jako zadanie z niejawnie zadaniem czasem zakończenia [84].

Również i w tym przypadku zadanie sprowadza się do określenia ciągu decyzji $(\pi^*(1), \pi^*(2), \dots, \pi^*(\underline{K}_2 - 1))$, takiego że:

$$\begin{aligned} Q^{pd}(\pi^*(1), \pi^*(2), \dots, \pi^*(\underline{K}_2 - 1); \hat{\xi}(1), \hat{\xi}(2), \dots, \hat{\xi}(\underline{K}_2)) &= \\ &= \min_{\pi(1), \pi(2), \dots, \pi(\underline{K}_2 - 1) \in \mathcal{N}} Q^{pd}(\pi(k_2), \hat{\xi}(k_2)), \end{aligned} \quad (2.52)$$

gdzie \underline{K}_2 to nieznan z góry czas zakończenia, który spełnia warunek: $\underline{K}_2 < \infty$. Dla następującego wskaźnika jakości $Q^{pd}(\cdot, \cdot)$:

$$\begin{aligned} Q^{pd}(\pi^*(1), \pi^*(2), \dots, \pi^*(\underline{K}_2 - 1); \hat{\xi}(1), \hat{\xi}(2), \dots, \hat{\xi}(\underline{K}_2)) &= \\ &= \sum_{k_2=1}^{\underline{K}_2} q^{pd}(\pi(k_2), \hat{\xi}(k_2)), \end{aligned} \quad (2.53)$$

Proces wspomagania podejmowania decyzji dla obiektu stochastycznego z niejawnie zadaniem czasem zakończenia

Podobnego sformułowania problemu można dokonać dla przypadku, gdy pomiary dokonywane były w obecności zakłóceń $\mathbf{z}(k_2)$, których wpływ na wyjście obiektu opisuje zależność: $\tilde{\xi}(k_2) = g_z(\hat{\xi}(k_2), \mathbf{z}(k_2))$ (Rysunek 2.7). Również i to zadanie sprowadza się do wyznaczenia sekwencji decyzji $(\pi^*(1), \pi^*(2), \dots, \pi^*(\underline{K}_2 - 1))$ takich, że:

$$\begin{aligned} \mathbb{E} \left[Q^{pd}(\pi^*(1), \pi^*(2), \dots, \pi^*(\underline{K}_2 - 1); \tilde{\xi}(1), \tilde{\xi}(2), \dots, \tilde{\xi}(\underline{K}_2)) \right] &= \\ &= \min_{\pi(1), \pi(2), \dots, \pi(\underline{K}_2 - 1) \in \mathcal{N}} \mathbb{E} \left[Q^{pd}(\pi(k_2), \tilde{\xi}(k_2)) \right], \end{aligned} \quad (2.54)$$

Dla następującego wskaźnika jakości $Q^{pd}(\cdot, \cdot)$:

$$\begin{aligned} Q^{pd}(\pi^*(1), \pi^*(2), \dots, \pi^*(\underline{K}_2 - 1); \tilde{\xi}(1), \tilde{\xi}(2), \dots, \tilde{\xi}(\underline{K}_2)) &= \\ &= \sum_{k_2=1}^{\underline{K}_2} q^{pd}(\pi(k_2), \tilde{\xi}(k_2)), \end{aligned} \quad (2.55)$$

Proces wspomagania podejmowania decyzji dla obiektu deterministycznego z rozmytym czasem zakończenia

Powyżej przedstawiono zadania, w których czas zakończenia jest ustalony w sposób jawny K_2 bądź w sposób niejawny tj. \underline{K}_2 .

W tym podpunkcie oraz w następnym sformułowano zadanie z rozmytym czasem zakończenia. W rzeczywistości z miękkiej definicji czasu zakończenia można skorzystać w sytuacji, gdy chcemy zaznaczyć, że pewien proces skończy się mniej więcej w czasie \underline{K}_2 [84].

Zadanie z rozmytym czasem zakończenia sprowadza się do zadania wyznaczenia optymalnej sekwencji decyzji $(\pi^*(1), \pi^*(2), \dots, \pi^*(\underline{K} - 1))$, gdzie \underline{K}_2 to optymalny czas zakończenia. Ostatecznie otrzymujemy:

$$\begin{aligned} Q^{pd}(\pi^*(1), \pi^*(2), \dots, \pi^*(\underline{K}_2 - 1); \hat{\xi}(1), \hat{\xi}(2), \dots, \hat{\xi}(\underline{K}_2)) &= \\ &= \min_{\pi(1), \pi(2), \dots, \pi(\underline{K}_2-1) \in \mathbb{N}} Q^{pd}(\pi(k_2), \hat{\xi}(k_2)), \end{aligned} \quad (2.56)$$

Dla następującego wskaźnika jakości $Q^{pd}(\cdot, \cdot)$:

$$\begin{aligned} Q^{pd}(\pi^*(1), \pi^*(2), \dots, \pi^*(\underline{K}_2 - 1); \hat{\xi}(1), \hat{\xi}(2), \dots, \hat{\xi}(\underline{K}_2)) &= \\ &= \sum_{k_2=1}^{\underline{K}_2} q^{pd}(\pi(k_2), \hat{\xi}(k_2)), \end{aligned} \quad (2.57)$$

Proces wspomagania podejmowania decyzji dla obiektu stochastycznego z rozmytym czasem zakończenia

W ostatnim z podpunktów, które dotyczą różnych sformułowań zadania wspomagania podejmowania decyzji również opisano zadanie z rozmytym czasem zakończenia. Różnica w stosunku do zadania poprzedniego jest taka, że sekwencja decyzji generowana jest w oparciu o zakłócone pomiary. Również i w tym przypadku, zakłócenia oznaczono jako $\mathbf{z}(k_2)$, natomiast $\tilde{\xi}(k_2) = g_z(\hat{\xi}(k_2), \mathbf{z}(k_2))$ jako funkcję opisującą jak zakłócenia wpływają na wyjście obiektu (Rysunek 2.7).

Zadanie sprowadza się do:

$$\begin{aligned} \mathbb{E} \left[Q^{pd}(\pi^*(1), \pi^*(2), \dots, \pi^*(\underline{K}_2 - 1); \tilde{\xi}(1), \tilde{\xi}(2), \dots, \tilde{\xi}(\underline{K}_2)) \right] &= \\ &= \min_{\pi(1), \pi(2), \dots, \pi(\underline{K}_2-1) \in \mathbb{N}} \mathbb{E} \left[Q^{pd}(\pi(k_2), \tilde{\xi}(k_2)) \right], \end{aligned} \quad (2.58)$$

Dla następującego wskaźnika jakości $Q^{pd}(\cdot, \cdot)$:

$$\begin{aligned} Q^{pd}(\pi^*(1), \pi^*(2), \dots, \pi^*(\underline{K}_2 - 1); \tilde{\xi}(1), \tilde{\xi}(2), \dots, \tilde{\xi}(\underline{K}_2)) = \\ = \sum_{k_2=1}^{\underline{K}_2} q^{pd}(\pi(k_2), \tilde{\xi}(k_2)), \end{aligned} \quad (2.59)$$

Rozwiązując sformułowane zadania tj.: (2.48), (2.52) oraz (2.56) zadania wspomaganie podejmowania decyzji dla obiektu deterministycznego otrzymamy dokładny algorytm wyboru sekwencji sterującej dla zadania:

– z ustalonym z góry czasem zakończenia \underline{K}_2 postaci:

$$\pi^*(k_2) = \psi^{pd}(\hat{\xi}(k_2)), \quad (2.60)$$

– z niejawnie zadanym czasem zakończenia \underline{K}_2 postaci:

$$\pi^*(k_2) = \psi^{pd}(\hat{\xi}(k_2)), \quad (2.61)$$

– z rozmytym czasem zakończenia \underline{K}_2 postaci:

$$\pi^*(k_2) = \psi^{pd}(\hat{\xi}(k_2)), \quad (2.62)$$

oraz $\hat{\xi}(\cdot) \in D_{\hat{\xi}(\cdot)}^*$, takiego że:

$$D_{\hat{\xi}(\cdot)}^* = \left\{ \hat{\xi}(\cdot) : Q^{pd}(\pi^*(\cdot), \hat{\xi}(\cdot)) < Q^{pd}(\pi(\cdot), \hat{\xi}(\cdot)) \quad \forall \pi \in \mathbb{N} \right\}. \quad (2.63)$$

Dla zadania z zakłóconymi pomiarami $\hat{\xi}(k_2)$ można przedstawić analogiczny algorytm z tą różnicą, że do wspomaganie podejmowania decyzji nie wykorzystujemy dokładnej wartości $\hat{\xi}(k_2)$, lecz wartość, na którą nałożone zostały pewne zakłócenia pomiarowe $z(k_2)$ Funkcja opisująca wpływ zakłóceń oznaczona została jako $g_z(\cdot, \cdot)$ (zadania 2.50, 2.54 oraz 2.58).

Dyskusja

Przedstawione powyżej zadanie poszukiwania optymalnej sekwencji scenariuszy można rozwiązać przy wykorzystaniu programowania dynamicznego. Podejście to polega na dekompozycji zadania na mniejsze podproblemy i ich systematyczne rozwiązywanie [96].

Omawiane zadanie poszukiwania sekwencji decyzji można również rozwiązać bazując na numerycznych metodach optymalizacji. Ogólny schemat postępowania

został przedstawiony w [126]. Procedurę można opisać jako iteracyjne poszukiwanie rozwiązania z wykorzystaniem np. metody Newtona.

Ważną grupą metod, które wykorzystywane są w różnorodnych zadaniach optymalizacji są procedury występujące pod wspólną nazwą metod uczenia ze wzmocnieniem [49], [125]. Do najczęściej wykorzystywanych algorytmów z tej grupy można zaliczyć procedurę *Q-learning* oraz metodę różnic czasowych [49].

Pewną odmianą metod uczenia ze wzmocnieniem są algorytmy uczenia z nadzorem. W procedurach tych wykorzystywana jest informacja zawarta w ciągu uczącym odnośnie pożądaných wartości na wyjściu systemu. Rozwiązania uzyskiwane przy wykorzystaniu tych metod, co jest warte podkreślenia, są tylko rozwiązaniami przybliżonymi. W wielu praktycznych zastosowaniach nie jest to jednak poważne ograniczenie. Zaletą tego podejścia jest natomiast możliwość szybkiego uzyskania satysfakcjonującego rozwiązania.

2.3.3 Adaptacyjne zadanie wspomaganie podejmowania decyzji

Opis zadania

Dokładne wyznaczenie sekwencji $\{\pi(k_2)\}_{k_2=1}^{K_2}$ z wykorzystaniem algorytmów (2.60) – (2.62) jest zadaniem trudnym obliczeniowo. Proces poszukiwania rozwiązania może zostać przyspieszony poprzez wykorzystanie procedur bazujących na przygotowanych wcześniej ciągach uczących. W rozpatrywanym zadaniu algorytm wyznaczania sekwencji scenariuszy można podzielić na kilka etapów. W pierwszym z nich wyznaczamy parametr $\hat{\mathbf{a}}_{1N_1}(k_2)$, który charakteryzuje aktualny stan obiektu. Następnie, wyznaczona wartość porównywana jest z tymi, które zgromadzone są w ciągu uczącym i podejmowana jest decyzja odnośnie scenariusza $\pi \in \mathbb{N}$, który powinien zostać zrealizowany w $(k_2 + 1)$ -tym kroku.

W zaproponowanej procedurze podejmowania decyzji wykorzystano algorytmy rozpoznawania obiektów. Powyższy podpunkt zawiera sformułowanie problemu. Przedstawiono również zestaw procedur niezbędnych do jego rozwiązania.

2.3.4 Sformułowanie problemu adaptacyjnego wspomaganie decyzji

Dla ustalonej sekwencji różnic pomiędzy wektorem parametrów obiektu $\hat{\mathbf{a}}_1$ w danej chwili na pierwszym stopniu a wartością pożądaną tego wektora \mathbf{a}_1^* dobrano

odpowiednią sekwencję scenariuszy i zaproponowano następujący ciąg uczący:

$$\mathbf{X}^{K^{pd}} = \left\{ \left(\tilde{\xi}_1, \pi_{h_1}^* \right), \left(\tilde{\xi}_2, \pi_{h_2}^* \right), \dots, \left(\tilde{\xi}_{K^{pd}}, \pi_{h_{K^{pd}}}^* \right) \right\}. \quad (2.64)$$

gdzie K^{pd} określa długość ciągu uczącego, natomiast $\tilde{\xi}_i$ charakteryzuje aktualny stan obiektu (2.47).

Do oceny wyników procesu wspomaganego podejmowania decyzji zaproponowano następujący wskaźnik jakości Q^{pd} dla zadania podejmowania decyzji:

$$Q^{pd} \left(\pi^*(1), \pi^*(2), \dots, \pi^*(K_2); \tilde{\xi}(1), \tilde{\xi}(2), \dots, \tilde{\xi}(K_2-1) \right) = \sum_{k_2=1}^{K_2} q^{pd}(\tilde{\xi}(k_2)). \quad (2.65)$$

Dane, które zostaną wykorzystane w ciągu uczącym mogą być w nim gromadzone na dwa sposoby. Pierwszy sposób polega na zamieszczeniu w tym zbiorze dokładnych rozwiązań zadania opisanego w podpunkcie 2.3.2 dla kilku wybranych przypadków. Następnie, tak przygotowany zbiór jest wykorzystywany w procesie wspomaganego podejmowania decyzji.

Jeżeli nie ma możliwości rozwiązania zadania w opisanym powyżej sposób, alternatywą dla opisanego metodologii jest wykorzystanie wiedzy eksperta. Również i w tym wypadku gromadzimy w ciągu uczącym informację o pożądanym wartościach wyjścia w zależności od wejścia. W tym wypadku wiedzę o tym, jak podejmować decyzję uzyskujemy od eksperta.

Systemy rozmyte w zadaniu wspomaganego podejmowania decyzji

Zaproponowana przez L. Zadeh koncepcja zbiorów rozmytych, które od tego czasu są intensywnie rozwijane, została wykorzystana do rozwiązania wielu praktycznych problemów z różnych dziedzin tj. sterowania, rozpoznawanie obiektów czy też identyfikacji. Warto wspomnieć, że oprócz systemów komputerowych dostępne są na rynku również urządzenia automatyki takie jak regulatory czy też sprzęt powszechnego użytku, w których z powodzeniem wykorzystuje się algorytmy oparte na systemach rozmytych. Świadczy to, z jednej strony o ich szerokim zastosowaniu, jak również o tym, że mogą być wykorzystywane w systemach o ograniczonej mocy obliczeniowej czy też dostępnej pamięci operacyjnej.

W pracy [8] omówione zostały główne cechy systemów bazujących na omawianym podejściu. Wśród tych najważniejszych, które warto omówić, należy wymienić możliwość łatwego osadzania w takich systemach (np. typu Takagi–Sugeno,

T - S) wiedzy eksperta. Szczególnie wygodnym w tym względzie wydaje się być wspomniany system typu T - S , w którym następniki mają postać rozmytą. Natomiast w części poprzedników są to zależności funkcyjne.

W omawianych systemach istnieją dwa główne sposoby wykorzystania w systemach rozmytych wiedzy eksperta [57]:

- poprzez bezpośrednie ustalanie wartości parametrów funkcji przynależności;
- poprzez wykorzystanie odpowiednio przygotowanych algorytmów uczenia, które wykorzystując wcześniej przygotowane ciągi uczące ustalają parametry funkcji przynależności.

Zastosowanie systemów typu T - S jest bardzo szerokie a samo podejście bardzo elastyczne. W pracy [127] dokonano analizy efektywności omawianego podejścia w zadaniu wspomagania podejmowania decyzji, natomiast w [44] zaproponowano rozmyty regulator pracujący w systemie z opóźnieniem czasowym pomiędzy sygnałem wejściowym i wyjściowym.

Kolejną ważną cechą systemów rozmytych jest ich odporność [139] i stabilność [83], [91], [118].

Wymienione powyżej własności sprawiły, że systemy rozmyte, w tym również system typu T - S są często łączone z innymi systemami. Do najpopularniejszych należą systemy nazywane w polskiej literaturze systemami neuronowo-rozmytymi [132], [139], [144].

Kolejnym rozszerzeniem omawianych systemów było zaproponowanie rekurencyjnych systemów neuronowo-rozmytych [100], [132].

Na koniec warto też wymienić kilka prac, w których omówiono efekty wykorzystania podejścia rozmytego w zadaniach praktycznych np. [102], [140].

2.3.5 Adaptacyjny algorytm wspomagania podejmowania decyzji

Biorąc pod uwagę zależności z poprzedniego podrozdziału, algorytm podejmowania decyzji bazujący na wiedzy eksperta można zapisać w formie:

$$\tilde{\pi}^*(k_2 + 1) = \psi_{PR}^{pd}(\tilde{\xi}(k_2), \mathbf{X}^{K_{pd}}; \mathbf{b}), \quad (2.66)$$

gdzie \mathbf{b} jest wektorem parametrów adaptacyjnego algorytmu podejmowania decyzji.

Zaproponowany w pracy algorytm podejmowania decyzji bazującego na procedurach rozpoznawania jest modyfikacją klasycznych metod z ich współczesnymi

odmianami tj. metodami bazującymi na systemach rozmytych czy też systemach neuronowo-rozmytych.

System Takagi–Sugeno jako adaptacyjny algorytm podejmowania decyzji

Poniżej został przedstawiony algorytm podejmowania decyzji z wykorzystaniem rozmytego systemu typu *Takagi–Sugeno* (T – S).

W zaproponowanym rozwiązaniu wykorzystano H_{PR} systemów rozmytych typu T – S , z których każdy został wstępnie przygotowany do rozpoznawania jednej z klas. Zestaw R_{PR} reguł ma postać:

$$\begin{aligned} \mathcal{R}^{(r_{PR})} : \text{ JEŻELI } \tilde{\xi}(k_2) \text{ jest } \mathcal{B}^{(r_{PR})} \\ \text{ TO } \underline{\alpha}^{(r_{PR})}(k_2) = g^{(r_{PR})}\left(\mathbf{w}^{(r_{PR})}\tilde{\xi}(k_2) + w_0\right), \end{aligned} \quad (2.67)$$

gdzie $g^{(r_{PR})}(\cdot)$ jest funkcją konkluzji, $r_{PR} = 1, 2, \dots, R_{PR}$ jest liczbą reguł w bazie, $\mathcal{B}^{(r_{PR})}$ to wartość lingwistyczna przesłanki dla r_{PR} -tej reguły a $\mathbf{w}^{(r_{PR})} = [w^{(1)} \ w^{(2)} \ \dots \ w^{(R_1)}]^T$ jest wektorem parametrów modelu, natomiast:

$$\tilde{\xi}(k_2) = [\tilde{\xi}^{(1)} \ \tilde{\xi}^{(2)} \ \dots \ \tilde{\xi}^{(R_1)}]^T.$$

W celu otrzymania w pełni funkcjonalnego modelu z sygnałem wyjściowym, należy dokonać sumowania sygnałów pochodzących z poszczególnych wyjść $\underline{\alpha}^{(r_{PR})}(k_2)$. Do dalszych rozważań przyjęto gaussowski typ funkcji przynależności:

$$\vartheta^{(r_{PR})}(\tilde{\xi}(k_2); m^{(r_{PR})}, \sigma^{(r_{PR})})$$

postaci:

$$\vartheta^{(r_{PR})}(\tilde{\xi}(k_2); m^{(r_{PR})}, \sigma^{(r_{PR})}) = \exp\left(-\frac{1}{2} \sum_{r_1=1}^{R_1} \left(\frac{\tilde{\xi}^{(r_1)}(k_2) - m^{(r_{PR})}}{\sigma^{(r_{PR})}}\right)^2\right). \quad (2.68)$$

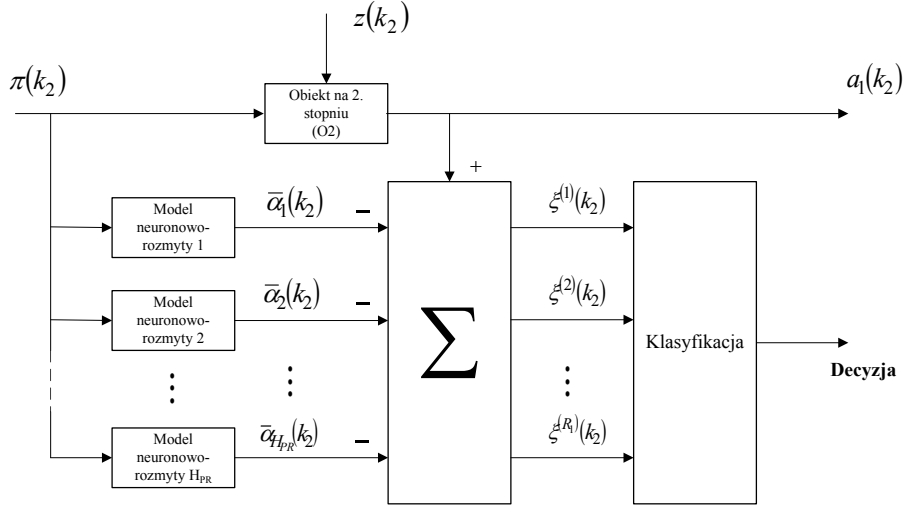
oraz regułę środka obszaru.

Dla tak przyjętych danych wyjście systemu rozmytego przyjmuje postać:

$$\bar{\alpha}(k_2 + 1) = \frac{\sum_{r_{PR}=1}^{R_{PR}} \exp\left(-\frac{1}{2} \sum_{r_1=1}^{R_1} \left(\frac{\tilde{\xi}^{(r_1)}(k_2) - m^{(r_{PR})}}{\sigma^{(r_{PR})}}\right)^2\right) \underline{\alpha}^{(r_{PR})}(k_2)}{\sum_{r_{PR}=1}^{R_{PR}} \exp\left(-\frac{1}{2} \sum_{r_1=1}^{R_1} \left(\frac{\tilde{\xi}^{(r_1)}(k_2) - m^{(r_{PR})}}{\sigma^{(r_{PR})}}\right)^2\right)}. \quad (2.69)$$

Procedurę wnioskowania rozmytego powtarzamy dla wszystkich H_{PR} systemów typu *Takagi–Sugeno*.

Ponieważ algorytm wyznaczania parametrów systemu rozmytego typu *Takagi–Sugeno* jest taki sam jak dla przedstawionego w podrozdziale 2.2.9, więc w bieżącym został pominięty. Należy jedynie zauważyć, że do wyznaczania parametrów powyższego systemu wykorzystywana jest sekwencja ucząca (2.64).



Rysunek 2.8: Schemat systemu wspomaganego podejmowania decyzji oparty na banku modeli neuronowo-rozmytych

2.3.6 Analiza zbieżności adaptacyjnego algorytmu wspomaganego podejmowania decyzji

Zaproponowany w podpunkcie 2.3.5 algorytm wspomaga wybór w kolejnych krokach (k_2) scenariusza $\tilde{\pi}(k_2)$ ze zbioru \aleph (2.3) przy spełnieniu warunku: $\{\tilde{\pi}(k_2)\}_{k_2=1}^{K_2} \in \aleph$. W rozpatrywanym zadaniu celem jest taki dobór sekwencji scenariuszy, aby wektor parametrów $\hat{\mathbf{a}}_1$ osiągnął pożądaną wartość tj. \mathbf{a}_1^* . Przykładając do obiektu w kolejnych krokach (k_2) sterowanie generowane na podstawie wybranego scenariusza $\tilde{\pi}(k_2)$ zmianie ulega wartość $\hat{\xi}(k_2)$ (2.47). Powyższy proces można opisać następującym równaniem:

$$\hat{\xi}(k_2) = \mathcal{H}(\hat{\xi}(k_2 - 1), \tilde{\pi}(k_2)), \quad (2.70)$$

gdzie $\mathcal{H}(\cdot, \cdot)$ jest pewnym nieznanym *explicite* funkcjonalem.

Omawiany algorytm podejmowania decyzji ψ^{pd} wykorzystany w zadaniu wspomagania podejmowania decyzji, można rozpatrywać jako łańcuch Markowa [117], [145], [157]. W analizowanym zadaniu, zaproponowana procedura w kolejnych krokach (k_2) wyznacza scenariusze $\tilde{\pi}(k_2) \in \aleph$ zawierające zestawy instrukcji do wykonania. Wykorzystanie teorii łańcuchów Markowa umożliwi przeprowadzenie analizy stabilności procesu wspomagania podejmowania decyzji.

W podpunkcie 2.3.1 zdefiniowany został pewien stochastyczny układ sterujący, który charakteryzuje się skończoną przestrzenią stanów \mathbb{S} (2.46) tj.

$$\mathbb{S} = \{s_1, s_2, \dots, s_F\}.$$

Oznaczmy przez Ψ pewien operator: $\Psi : \mathbb{S} \rightarrow \aleph$ tj. $\tilde{\pi}(k_2) = \Psi(s(k_2)) \in \aleph$. W wyniku podjętej akcji podejmowania decyzji omawiany układ przechodzi ze stanu $s(k_2)$ do stanu $s(k_2 + 1)$ z pewnym określonym prawdopodobieństwem $p(s(k_2), s(k_2 + 1))$. Prawdopodobieństwo to określone jest dla łańcucha Markowa pewną macierzą przejścia \mathbf{P} .

Zdefiniujmy przestrzeń probabilistyczną $(\Omega, \mathcal{F}, \mathbb{P})$ wraz z filtracją $\mathcal{F}(k_2)$. Niech przestrzeń \mathbb{S} będzie przestrzenią mierzalną dla rozpatrywanego procesu.

Niech wygenerowany przez algorytm podejmowania decyzji (2.66) ciąg $\{\tilde{\pi}(k_2)\}_{k_2=1}^{K_2}$ będzie postaci:

$$\mathcal{F}(k_2) = \sigma\{\hat{\mathbf{a}}_1(1), \hat{\mathbf{a}}_1(2), \dots, \hat{\mathbf{a}}_1(K_2)\}. \quad (2.71)$$

Wówczas $(\psi^{pd}(\hat{\xi}(k_2); \mathbf{b}), \mathcal{F}(k_2))$ nazywamy łańcuchem Markowa wraz z operatorem przejścia \mathbf{P} oraz rozkładem początkowym $\mu(0)$ [80].

W pracy [98] zaznaczono, że w układach sterowania bądź wspomagających podejmowanie decyzji istnieje swoboda w wyborze postaci macierzy stochastycznej i to od nas zależy, czy w analizie wykorzystamy macierz jednorodną czy też niejednorodną.

Jednorodny łańcuch Markowa można opisać przy wykorzystaniu pewnego rozkładu początkowego $\mu(0)$ oraz macierzy przejścia \mathbf{P} postaci:

$$\mathbf{P} = \begin{bmatrix} p(1,1) & p(1,2) & \cdots & p(1,F) \\ p(2,1) & p(2,2) & \cdots & p(2,F) \\ \vdots & \vdots & \ddots & \vdots \\ p(F,1) & p(F,2) & \cdots & p(F,F) \end{bmatrix} \quad (2.72)$$

gdzie $p_{(i,j)}$ reprezentuje prawdopodobieństwo przejścia z poszczególnych stanów w kolejnych krokach, dla których spełniony jest warunek:

$$\sum_{j=1}^F p_{(i,j)} = 1, \quad p_{(i,j)} \geq 0. \quad (2.73)$$

Poszczególne elementy macierzy \mathbf{P} wyznaczone są zgodnie z zależnością:

$$\begin{aligned} p_{(i,j)}(k_2, k_2 + 1) &= \\ &= \mathbb{P}\left(s(k_2) = \psi_{PR}^{pd}(\hat{\xi}(j); \mathbf{b}) \mid s(k_2 - 1) = \psi_{PR}^{pd}(\hat{\xi}(i); \mathbf{b})\right) = \\ &= \mathbb{P}\left(s(k_2) = \psi_{PR}^{pd}(\hat{\xi}(j); \mathbf{b}) \mid s(1) = \psi_{PR}^{pd}(\hat{\xi}(i_1); \mathbf{b}), s(2) = \right. \\ &= \left. \psi_{PR}^{pd}(\hat{\xi}(i_2); \mathbf{b}), \dots, s(k_2 - 2) = \right. \\ &= \left. \psi_{PR}^{pd}(\hat{\xi}(i_{k_2-2}); \mathbf{b}), s(k_2 - 1) = \psi_{PR}^{pd}(\hat{\xi}(i); \mathbf{b})\right). \end{aligned} \quad (2.74)$$

Jeżeli wpływ rozkładu początkowego $\mu(0)$ na pewien ustalony stan $\mu(k_2)$ systemu maleje gdy $k_2 \rightarrow K_2$ mówimy wówczas o stacjonarnym łańcuchu Markowa. Dla takiego łańcucha zachodzi:

$$\mu = \mu \mathbf{P}, \quad (2.75)$$

gdymy:

$$\sum_{h=1}^F \mu^{(h)} = 1, \quad (2.76)$$

dla każdego stanu, oraz:

$$\mu^{(j)} = \sum_i \mu^{(i)} p_{(i,j)}, \quad (2.77)$$

gdzie: $\mu = [\mu^{(1)} \quad \mu^{(2)} \quad \dots \quad \mu^{(F)}]^T$ jest odpowiednio unormowanym wektorem wartości własnych macierzy \mathbf{P} .

Korzystając z (2.76) oraz (2.77) możemy podać warunek wystarczający stacjonarności łańcucha Markowa tj. wartość własna macierzy \mathbf{P} w każdym kroku (k_2) musi spełniać warunek $0 < \mu^{(f)} < 1$ oraz (2.76).

Wówczas, jeżeli łańcuch jest stacjonarny to [80]:

$$\lim_{k_2 \rightarrow K_2} p_{(i,j)}(k_2) = \mu. \quad (2.78)$$

Powyżej procedura podejmowania decyzji została opisana jako łańcuch Markowa. Natomiast poniżej dokonano analizy zbieżności procesu wspomaganego podejmowania decyzji przy wykorzystaniu procedury, którą można zapisać ogólnie w postaci równania (2.70).

Analiza zbieżności pozwala określić, czy przy wykorzystaniu zaprojektowanej procedury możliwe jest wygenerowanie takiego ciągu zmiennych losowych $\{\hat{\xi}(k_2)\}_{k_2=1}^{K_2}$, które będą zbieżne do pewnej liczby, tj. $\hat{\xi}(k_2) \rightarrow \hat{\xi}^*$ albo pewnego zbioru $\hat{\xi}(k_2) \rightarrow \hat{\Xi}^*$, przy ustalonych pewnych warunkach początkowych i pewnym zbiorze sygnałów sterujących $\{\tilde{\pi}(k_2)\}_{k_2=1}^{K_2}$ pochodzących ze zbioru \aleph . Dodatkowo, szczególnie dokonując analizy procesów rzeczywistych, ważnym zagadnieniem jest analiza wpływu zaburzeń (np. pod wpływem zmieniających się warunków zewnętrznych, zakłóceń pomiarowych itp.) na zbieżność procesu. W takim przypadku zaproponowane równanie można przekształcić do postaci:

$$\hat{\xi}(k_2 + 1) = \mathcal{H}\left(\tilde{\pi}(k_2); g_w(\hat{\xi}(k_2), w(k_2))\right).$$

gdzie $w(k_2)$ to pewne zakłócenie.

Zbieżność ciągów funkcji lub wielkości losowych można określać na różne sposoby. Pamiętać należy przy tym, że ciąg który jest zbieżny według jednego z określeń nie musi być zbieżny w odniesieniu do innego. Najsilniejszą zbieżność, która gwarantuje zbieżność w zwykłym sensie jest zbieżność z prawdopodobieństwem 1 (inaczej: prawie na pewno). Dla tak określonej zbieżności wszystkie ciągi $\{\hat{\xi}(k_2)\}_{k_1=1}^{K_1}$ dążą do $\hat{\xi}^*$, tj. $\hat{\xi}(k_2) \xrightarrow{p.1} \hat{\xi}^*$.

Słabszym określeniem zbieżności jest zbieżność według prawdopodobieństwa. Proces który charakteryzuje się tak określoną zbieżnością nie gwarantuje, że dla każdej z realizacji ciągu $\{\hat{\xi}(k_2)\}_{k_1=1}^{K_1}$ będzie on zbiegał do określonej wartości gdy $k_2 \rightarrow K_2$. Zbieżność tą nazywa się również słabą zbieżnością. Oprócz dwóch wymienionych możemy wyróżnić jeszcze zbieżność według rozkładu oraz według *r-tego momentu* [2], [80].

Zapisane na początku podrozdziału równanie (2.70) może być równaniem nieliniowym, którego teoretyczna analiza może być bardzo trudno bądź niemożliwa. W latach siedemdziesiątych ubiegłego wieku L. Ljung przedstawił ogólną metodę analizy tego typu równań. Autor zaproponował wykorzystanie zaproponowanej metodologii do badania rekurencyjnych algorytmów identyfikacji [105]. Propozycje innych metod bądź rozszerzenie istniejących zaproponowane zostały między

innymi w pracach [14], [54], [116]. Na uwagę zasługuje również [99], [46], [79], [93], w których zawarty został wyczerpujący opis omawianego podejścia.

Omówiony w 2.3.2 proces podejmowania decyzji (2.66) w zaproponowanym systemie (Rysunek 2.3) można zapisać w postaci:

$$\hat{\xi}(k_2 + 1) = \hat{\xi}(k_2) + \gamma(k_2) \left(\mathcal{H}(\tilde{\pi}(k_2); \hat{\xi}(k_2)) \right), \quad (2.79)$$

gdzie $\mathcal{H}(\tilde{\pi}(k_2); \hat{\xi}(k_2))$ to pewien funkcjonal, natomiast $\{\hat{\xi}(k_2)\}_{k_2=1}^{K_2}$ to ciąg realizacji zmiennej losowej.

Dodatkowo zakładamy, że [93], [98]:

$$\sum_{k_2=1}^{K_2} \gamma(k_2) = \infty, \quad (2.80)$$

$$\sum_{k_2=1}^{K_2} \gamma^2(k_2) < \infty \quad \text{dla} \quad \gamma(k_2) > 0 \quad \text{oraz} \quad \lim_{k_2 \rightarrow \infty} \gamma(k_2) = 0. \quad (2.81)$$

Zakładamy również addytywność zakłóceń pomiarowych, tj.:

$$\tilde{\xi}(k_2) = \hat{\xi}(k_2) + w(k_2). \quad (2.82)$$

Wówczas funkcjonal $\mathcal{H}(\cdot, \cdot)$ przyjmuje postać:

$$\mathcal{H}(\tilde{\pi}(k_2); \tilde{\xi}(k_2)) = \mathcal{H}(\tilde{\pi}(k_2), g_w(\hat{\xi}(k_2), w(k_2))). \quad (2.83)$$

Biorąc pod uwagę (2.82), równanie (2.79) możemy zapisać w postaci:

$$\hat{\xi}(k_2 + 1) = \hat{\xi}(k_2) + \gamma(k_2) \left(\mathcal{H}(\tilde{\pi}(k_2), \tilde{\xi}(k_2)) \right). \quad (2.84)$$

Przyjmijmy teraz, że istnieje pewna ciągła funkcja $h(\hat{\xi}(k_2))$ postaci:

$$h(\hat{\xi}(k_2)) = \mathbb{E} \left[\mathcal{H}(\tilde{\pi}(k_2), \tilde{\xi}(k_2)) \right]. \quad (2.85)$$

Wykorzystując (2.85), przekształćmy równanie (2.84) do postaci:

$$\hat{\xi}(k_2 + 1) = \hat{\xi}(k_2) + \gamma(k_2) (h(\hat{\xi}(k_2))) + \gamma(k_2) \left(\mathcal{H}(\tilde{\pi}(k_2), \tilde{\xi}(k_2)) - h(\hat{\xi}(k_2)) \right). \quad (2.86)$$

Wyrażenie po prawej stronie równania (2.86) oznaczmy jako:

$$\varepsilon(k_2) = h(\hat{\xi}(k_2)) - \mathcal{H}(\tilde{\pi}(k_2), \tilde{\xi}(k_2)).$$

Założmy jednocześnie, że można dokonać dekompozycji powyższego wyrażenia w następujący sposób [54], [88]:

$$\varepsilon(k_2) = \delta M(k_2) + \beta(k_2), \quad (2.87)$$

gdzie $\beta(k_2)$ maleje asymptotycznie do 0 gdy $k_2 \rightarrow \infty$ [99]. Natomiast $\delta M(k_2)$ to różnica martyngałowa [99]. Powyższe założenie jest usprawiedliwione, ponieważ procesy sterowane łańcuchami Markowa wykazują takie własności. Najprostszym przykładem martyngału jest suma ciągu niezależnych zmiennych losowych $M(k_2)$, dla których wartość średnia jest równa zero.

Ponieważ $\beta(k_2)$ dla dużych (k_2) jest pomijalnie małe, zależność (2.86) przyjmuje postać:

$$\hat{\xi}(k_2 + 1) = \hat{\xi}(k_2) + \gamma(k_2)h(\hat{\xi}(k_2 + 1)) + \delta M(k_2). \quad (2.88)$$

Zgodnie z [93] zachodzi $\mathbb{E}[\delta M(k_2 + 1)|\delta M(k_2) \text{ dla } k_2 < s] = 0$, gdzie s to czas zatrzymania. Dokonajmy przekształcenia zależności (2.88) do postaci:

$$\frac{\hat{\xi}(k_2 + 1) - \hat{\xi}(k_2)}{\gamma(k_2)} = h(\hat{\xi}(k_2)). \quad (2.89)$$

Interpolując powyższe równanie [98], możemy dokonać przekształcenia do postaci:

$$\frac{d\hat{\xi}(t)}{dt} = h(\hat{\xi}(t)). \quad (2.90)$$

Jeżeli funkcja $h(\cdot)$ jest ciągła i ograniczona, to równanie (2.90) ma stały punkt równowagi $\hat{\xi}^*$.

W dalszej części pracy przedstawiono analizę zbieżności procesu wspomagania podejmowania decyzji (rozdział 2) z wykorzystaniem algorytmu podejmowania decyzji. W tym celu posłużono się zaproponowaną powyżej metodą L. Ljunga. Z przeprowadzonej powyżej analizy wynika, że zaproponowaną procedurę możemy traktować jako łańcuch Markowa – pozwoli to na wykorzystanie teorii martyngałów [147].

W celu skupienia uwagi zredukujmy problem do zadania podejmowania decyzji ze zbioru dwuelementowego tj. $\{\pi_1, \pi_2\}$. Ponieważ w zadaniach praktycznych dostępna informacja probabilistyczna nie jest pełna, prowadzi to zwykle do zadania podejmowania decyzji ze zbiorem uczącym.

Niech w rozpatrywanym zadaniu ciąg uczący ma postać taką jak w podrozdziale 2.3.3 tj. (2.64). Zadanie wyboru scenariusz dla dwóch klas ma postać:

$$\psi_{PR}^{pd}(\hat{\xi}(k_2), \mathbf{X}^{K_{pd}}; \mathbf{b}) = \begin{cases} \tilde{\pi}_1 & \text{jeżeli } \bar{\alpha} \geq c \\ \tilde{\pi}_2 & \text{w przeciwnym przypadku} \end{cases}$$

gdzie $\bar{\alpha}$ jest wyjściem systemu *Takagi–Sugeno* w postaci (2.69), natomiast c to stała.

Zaproponujemy następującą funkcję Lapunowa:

$$V(k_2) = \frac{1}{2}(\hat{\xi}(k_2))^2, \quad (2.91)$$

gdzie $\hat{\xi}(k_2)$ jest różnicą pomiędzy wartością bieżącą a żadaną wektora parametrów $\hat{\mathbf{a}}_1(k_2)$:

$$\hat{\xi}(k_2) = d^{pd}(\mathbf{a}_1^*, \hat{\mathbf{a}}_1(k_2)).$$

Załóżmy, że na pomiar wielkości $\hat{\mathbf{a}}_1(k_2)$ wpływa zakłócenie addytywne, tj.:

$$\tilde{\xi}(k_2) = \hat{\xi}(k_2) + w(k_2). \quad (2.92)$$

Biorąc pod uwagę (2.92) zaproponowana funkcja Lapunowa przyjmuje postać:

$$V(k_2) = \frac{1}{2}(\tilde{\xi}(k_2))^2, \quad (2.93)$$

i ma następujące własności:

$$\left[\frac{\partial}{\partial \tilde{\pi}} V(\tilde{\xi}(k_2)) \right]^T h(\tilde{\xi}(k_2)) \leq 0, \quad (2.94)$$

$$\left[\frac{\partial}{\partial \tilde{\pi}} V(\tilde{\xi}(k_2)) \right]^T h(\tilde{\xi}(k_2)) = 0 \quad \text{gdy} \quad \tilde{\xi}(k_2) = \xi^* \quad \text{dla} \quad k_2 \rightarrow K_2, \quad (2.95)$$

gdzie $h(\cdot)$ spełnia własność (2.85).

Zaproponowany algorytm (2.66) wyznacza w kolejnych krokach (k_2) scenariusz bazując na bieżących wartościach $\tilde{\xi}(k_2)$. Pomiary tej wielkości dokonywane są z pewnym błędem, co można zapisać w postaci:

$$\tilde{\xi}(k_2) = \hat{\xi}(k_2) + \sum_{j=k_2+1}^{\infty} \gamma(j)M(j) + \beta(k_2), \quad (2.96)$$

gdzie $\beta(k_2)$ zgodnie z tym co zostało założone $\beta(k_2) \rightarrow 0$ gdy $k_2 \rightarrow \infty$. Ustalmy jednocześnie ciąg $v(k_2)$ postaci:

$$v(k_2) = - \sum_{j=k_2+1}^{\infty} \gamma(j)M(j), \quad (2.97)$$

Biorąc pod uwagę równości (2.87, 2.96, 2.97), zależność (2.86) możemy zapisać w postaci:

$$\begin{aligned}\tilde{\xi}(k_2 + 1) &= \hat{\xi}(k_2 + 1) + \sum_{j=k_2+1}^{\infty} \gamma(j)M(j) = \\ &= \hat{\xi}(k_2) + \gamma(k_2)h(\hat{\xi}(k_2)) + \gamma(k_2)\beta(k_2 + 1) + \\ &+ M(k_2 + 1) + \sum_{j=k_2+2}^{\infty} \gamma(j)M(j).\end{aligned}\quad (2.98)$$

gdzie $h(\cdot)$ to funkcja spełniająca warunek (2.85).

Dokonajmy przekształcenia (2.98) do postaci:

$$\begin{aligned}\tilde{\xi}(k_2 + 1) &= \hat{\xi}(k_2) - v(k_2) + \gamma(k_2)h(\hat{\xi}(k_2)) + v(k_2) + \gamma(k_2)\beta(k_2 + 1) = \\ &= \tilde{\xi}(k_2) + \gamma(k_2)h(\tilde{\xi}(k_2)) + \gamma(k_2)\beta'(k_2 + 1),\end{aligned}\quad (2.99)$$

gdzie $\beta'(k_2 + 1) = \beta(k_2) + h(\tilde{\xi}(k_2) + v(k_2)) - h(\hat{\xi}(k_2))$.

Zaznaczmy, że $\tilde{\xi}$ zależy od scenariusza, tj. $\tilde{\xi}(\tilde{\pi}(k_2))$. Korzystając z twierdzenia o wartości średniej możemy zapisać:

$$\begin{aligned}V(\tilde{\xi}(\tilde{\pi}(k_2 + 1))) &= V(\tilde{\xi}(\tilde{\pi}(k_2))) + \left[\frac{\partial}{\partial \tilde{\pi}} V(\tilde{\xi}^*) \right]^T \\ &\quad \left(\frac{\partial}{\partial \tilde{\pi}} V(\tilde{\xi}(\tilde{\pi}(k_2)) - \tilde{\xi}(\tilde{\pi}(k_2))) \right).\end{aligned}\quad (2.100)$$

W kolejnym kroku dokonujemy następującego przekształcenia powyższej zależności:

$$\begin{aligned}V(\tilde{\xi}(\tilde{\pi}(k_2 + 1))) &= V(\tilde{\xi}(\tilde{\pi}(k_2))) + \left[\frac{\partial}{\partial \tilde{\pi}} V(\tilde{\xi}^*) \right]^T (\gamma(k_2)h(\tilde{\xi}(\tilde{\pi}(k_2))) + \\ &+ \gamma(k_2)\beta'(\tilde{\pi}(k_2))) = V(\tilde{\xi}(\tilde{\pi}(k_2))) + \\ &+ \gamma(k_2) \left(\left[\frac{\partial}{\partial \tilde{\pi}} V(\tilde{\xi}^*) \right]^T h(\tilde{\xi}(\tilde{\pi}(k_2))) \right) + \\ &+ \gamma(k_2) \left(\left[\frac{\partial}{\partial \tilde{\pi}} V(\tilde{\xi}^*) \right]^T \beta'(k_2 + 1) \right).\end{aligned}\quad (2.101)$$

Ponieważ: $\beta'(k_2 + 1) = \beta(k_2) + h(\tilde{\xi}(\tilde{\pi}(k_2)) + v(k_2)) - h(\hat{\xi}(\tilde{\pi}(k_2)))$. Z własności martyngałów wiemy, że $v(k_2) \rightarrow 0$ gdy $k_2 \rightarrow \infty$. Wynika z tego, że $\beta' \rightarrow 0$ dla dużych k_2 . Prowadzi to do następującej zależności:

$$\begin{aligned}V(\tilde{\xi}(\tilde{\pi}(k_2 + 1))) &= V(\tilde{\xi}(\tilde{\pi}(k_2))) + \\ &+ \gamma(k_2) \left(\left[\frac{\partial}{\partial \tilde{\pi}} V(\tilde{\xi}^*) \right]^T h(\tilde{\xi}(\tilde{\pi}(k_2))) \right).\end{aligned}\quad (2.102)$$

Ponieważ założono, że funkcja $h(\cdot)$ jest ciągła oraz to, że wszystkie realizacje ciągu $\{\tilde{\xi}(k_2)\}_{k_2=1}^{K_2}$ są ograniczone, prowadzi to do następującego wniosku:

$$\tilde{\xi}(k_2) \xrightarrow{p.1} \xi^*$$

Dyskusja

Z przeprowadzonej w podrozdziale 2.3.6 analizy stabilności procesu wspomaganego podejmowania decyzji dla nieliniowego obiektu przy wykorzystaniu algorytmu wspomaganego podejmowania decyzji, który ma własności łańcucha Markowa, można określić czym powinna charakteryzować się sekwencja ucząca oraz podejmowane działania w wyniku podjętych decyzji 9wybranych scenariuszy).

Z zależności (2.102) oraz poczynionego wcześniej założenia o tym, że realizacje ciągu $\{\tilde{\xi}(k_2)\}_{k_2=1}^{K_2}$ są ograniczone wynika, że:

- błąd z jakim dokonywany jest pomiar zmiennej $\tilde{\xi}(k_2)$ musi być ograniczony;
- wielkość zmian $\tilde{\xi}(k_2)$ w wyniku podejmowanych decyzji musi być również ograniczona.

2.3.7 Adaptacyjne zadanie wspomaganego podejmowania decyzji ze strojeniem parametrów

Opis zadania

W rozdziale 2.3.3 zaproponowano algorytm podejmowania decyzji (2.66), który bazując na metodach rozpoznawania obiektów wyznacza ciąg decyzji. Zaproponowana procedura charakteryzuje się wektorem parametrów \mathbf{b} , którego wartość ustala się przed rozpoczęciem procesu wspomaganego podejmowania decyzji. W poniższym podrozdziale przedstawiony został zmodyfikowany algorytm, w którym można wyróżnić dwie warstwy: warstwę sterowania niskopoziomowego (algorytm opisany w rozdziale 2.3.3) oraz warstwę nadrzędną z adaptatorem [62], [65].

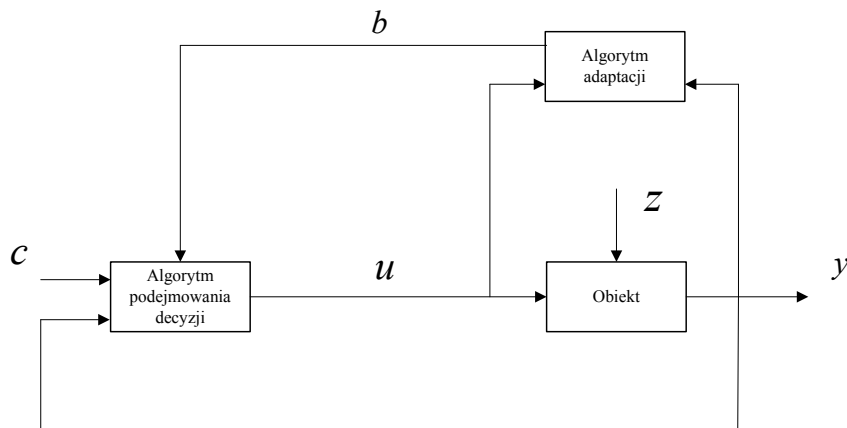
Dwustopniowe podejście do problemu identyfikacji pozwala na ustalenie zależności pomiędzy sekwencją sygnałów sterujących $\{\tilde{\pi}(k_2)\}_{k_2=1}^{K_2}$ (w rozpatrywanym zdaniu jest to sekwencja scenariuszy) a wewnętrznym parametrem $\{\hat{\mathbf{a}}_1(k_2)\}_{k_2=1}^{K_2}$, który charakteryzuje aktualny stan obiektu (podrozdział 1.6) w chwili (k_2) . Wartość tego parametru może zostać wykorzystana przez adaptator (1.6) do przestrajania algorytmu podejmowania decyzji (poprzez zmianę wartości wektora pa-

parametrów \mathbf{b}). Opisana powyżej idea adaptacji zwana jest adaptacją poprzez identyfikację [42].

Drugą koncepcją, która może zostać wykorzystana w adaptacyjnych systemach wspomaganie podejmowania decyzji jest adaptacja poprzez strojenie [33]. W tym przypadku zadanie sprowadza się do zadania sterowania ekstremalnego badanym obiektem w systemie zamkniętym (Rysunek 2.9).

W celu zmodyfikowania zaproponowanej procedury podejmowania decyzji (2.3.3) należy zaprojektować odpowiedni algorytm dla adaptatora, którego zadaniem jest dobór parametru zaproponowanego algorytmu. Efektem działania adaptatora będzie sekwencja $\{\mathbf{b}(m)\}_{m=1}^M$, gdzie m jest taktem strojenia algorytmu podejmowania decyzji ψ_{PR}^{pd} . Warto podkreślić jest to, że podobnie jak w omawianym algorytmie wspomaganie podejmowania decyzji, również i w tym przypadku wykorzystana zostanie odpowiednio przygotowana sekwencja ucząca.

Koncepcję adaptacyjnych systemów wspomagających podejmowanie decyzji rozpatrywano już w latach sześćdziesiątych ubiegłego wieku [52]. W pracy tej autor dokonał podziału adaptacyjnych systemów wspomagających podejmowanie decyzji na dwie główne grupy: systemów uczących się (*ang. self-learning*) oraz systemów uczących się ze wzmocnieniem (*ang. reinforcement learning*). Dekadę później do dyskutowanej koncepcji wrócił K.J. Astrom [5]. Wśród polskich autorów można wymienić min. prace [42], [62], [63], [121], [122], [123].



Rysunek 2.9: Idea adaptacji poprzez strojenie

Warto również wspomnieć o opracowaniach, w których opisane zostały aplikacje rzeczywistych problemów z wykorzystaniem adaptacyjnych algorytmów wspo-

magających podejmowania decyzji. W pracy [7] przedyskutowano rezultaty uzyskane dla zadania sterowania bioreaktorem. Koncepcja adaptacji może być również wykorzystywana w klasycznych problemach sterowania. Praca [59] zawiera opis wykorzystania omawianych algorytmów z zadaniem dostrajania parametrów regulatora PID.

2.3.8 Sformułowanie problemu adaptacyjnego wspomaganie decyzji ze strojeniem parametrów

Powyższy problem jest zadaniem optymalizacji, w którym dokonujemy minimalizacji zaproponowanego wskaźnika jakości $Q^s(b(m), \hat{\mathbf{a}}_2(m))$ (2.104) poprzez odpowiedni dobór wektora parametrów \mathbf{b} w każdym kroku wspomaganie podejmowania decyzji.

Założmy, że wektor parametrów \mathbf{b} algorytmu wykorzystywanego przez algorytm wspomagający podejmowanie decyzji pochodzi ze zbioru:

$$\mathbf{b} \in \mathbf{B} = \{\mathbf{b}_1, \mathbf{b}_2, \dots, \mathbf{b}_Z\}, \quad (2.103)$$

gdzie Z jest liczbą możliwych ustawień wektora parametrów urządzenia wspomagającego podejmowanie decyzji.

Zdefiniujmy odpowiedni wskaźnik jakości:

$$\begin{aligned} Q^s(\mathbf{b}(1), \mathbf{b}(2), \dots, \mathbf{b}(M); \hat{\mathbf{a}}_2(1), \hat{\mathbf{a}}_2(2), \dots, \hat{\mathbf{a}}_2(M)) &= \\ &= \sum_{m=1}^M q^s(\mathbf{b}(m), \hat{\mathbf{a}}_2(m)), \end{aligned} \quad (2.104)$$

gdzie $m = l \cdot k_2$ dla $l \in \mathcal{N}$.

Problem poszukiwania sekwencji $(\mathbf{b}^*(1), \mathbf{b}^*(2), \dots, \mathbf{b}^*(M))$ można sprowadzić do zadania optymalizacji:

$$\begin{aligned} Q^s(\mathbf{b}^*(1), \mathbf{b}^*(2), \dots, \mathbf{b}^*(M); \hat{\mathbf{a}}_2(1), \hat{\mathbf{a}}_2(2), \dots, \hat{\mathbf{a}}_2(M)) &= \\ &= \min_{\mathbf{b}(1), \mathbf{b}(2), \dots, \mathbf{b}(M) \in \mathbf{B}} Q^s(\mathbf{b}(m), \hat{\mathbf{a}}_2(m)), \end{aligned} \quad (2.105)$$

otrzymamy dokładny algorytm doboru wektora parametrów \mathbf{b} algorytmu (2.66):

$$\mathbf{b}^*(m+1) = \psi^s(\hat{\mathbf{a}}_2(m)), \quad (2.106)$$

gdzie $\hat{\mathbf{a}}_2(m) \in D_{\hat{\mathbf{a}}_2(m)}^*$, takiego że:

$$D_{\hat{\mathbf{a}}_2(m)}^* = \left\{ \hat{\mathbf{a}}_2(m) : Q^s(\mathbf{b}^*(m), \hat{\mathbf{a}}_2(m)) < Q^s(\mathbf{b}(m), \hat{\mathbf{a}}_2(m)) \quad \forall_{b(m) \in \mathbf{B}} \right\}. \quad (2.107)$$

2.3.9 Adaptacyjny algorytm wspomaganie podejmowania decyzji ze strojnym parametrem

Podobnie jak dla opisanego powyżej zadania wyboru sekwencji scenariuszy, zadanie doboru optymalnego parametru może okazać się zadaniem trudnym obliczeniowo. W zamian proponuje się rozwiązanie przybliżone, które bazuje na algorytmach rozpoznawania obiektów.

Dla opisanego zadania sekwencja ucząca przyjmuje postać:

$$\mathbf{X}^{K_s} = \left\{ \left(\hat{\mathbf{a}}_{21}, \mathbf{b}_{z_{21}}^* \right), \left(\hat{\mathbf{a}}_{22}, \mathbf{b}_{z_{22}}^* \right), \dots, \left(\hat{\mathbf{a}}_{2K_s}, \mathbf{b}_{z_{K_s}}^* \right) \right\}. \quad (2.108)$$

Wykorzystując opisany powyżej ciąg uczący zaproponowano przybliżony algorytm poszukiwania wartości wektora parametrów \mathbf{b} algorytmu podejmowania decyzji:

$$\tilde{\mathbf{b}}^*(m+1) = \psi_{PR}^s(\hat{\mathbf{a}}_2(m), \mathbf{X}^{K_s}). \quad (2.109)$$

Ostatecznie, algorytm podejmowania decyzji ze strojnym parametrem można zapisać w następującej formie:

$$\tilde{\pi}^*(k_2+1) = \psi_{PR}^{pd} \left(\hat{\xi}(k_2), \mathbf{X}^{K_{pd}}, \psi_{PR}^s(\hat{\mathbf{a}}_2(m), \mathbf{X}^{K_s}) \right), \quad (2.110)$$

Adaptator, którego zadaniem jest dostrajanie algorytmu podejmowania decyzji (2.66) poprzez zmianę wartości wektora parametrów \mathbf{b} w trakcie trwania procesu wspomaganie podejmowania decyzji, wykorzystywać będzie algorytm bazujący na procedurze najbliższa średnia (NM) [97] tj.:

$$\tilde{\mathbf{b}}^*(m+1) = \psi_{PR}^s(\hat{\mathbf{a}}_2(m), \mathbf{X}^{K_s}), \quad (2.111)$$

gdym:

$$\Gamma(\mathbf{X}^{K_s}(i)) = \frac{1}{V_i} \sum_{l \in \mathcal{X}^{K_s}} \mathbf{X}^{K_s}(l), \quad i = 1, 2, \dots, M.$$

gdzie \mathcal{X}^{K_s} to podzbiór zbioru \mathbf{X}^{K_s} , natomiast V_i oznacza liczbę elementów zbioru \mathcal{X}^{K_s} . Oznacza to, że dla każdej klasy wyliczamy średnią arytmetyczną cech

obrazów z ciągu uczącego [97]. W ostatnim kroku należy rozwiązać następujące zadanie optymalizacji:

$$\mathbf{b} = \min_{l \in \mathcal{X}^{K_s}} q^s(\hat{\mathbf{a}}_2(m), \Gamma(\mathbf{X}^{K_s}(l))).$$

2.3.10 Analiza zbieżności adaptacyjnego algorytmu wspomaganego podejmowania decyzji ze strojnym parametrem

W podpunkcie 2.3.6 dokonano formalnej analizy stabilności procesu wspomaganego podejmowania decyzji z wykorzystaniem zaproponowanego algorytmu podejmowania decyzji. Zaproponowany algorytm (2.66) został opisany jako łańcuch Markowa. W podpunkcie 2.3.9 przedstawiono modyfikację algorytmu (2.66) w którym to parametr \mathbf{b} jest dostrajany w trakcie trwania procesu wspomaganego podejmowania decyzji.

W tym przypadku analizowany algorytm (2.106) będzie rozpatrywany jako sterowany łańcuch Markowa, tj.

$$\left(\psi^{pd}(\hat{\xi}(k_2), \mathbf{X}^{K_{pd}}; \psi_{PR}^s(\hat{\mathbf{a}}_2(m), \mathbf{X}^{K_s})), \mathcal{F}(m) \right).$$

Generowana sekwencja $\{\tilde{\pi}(k_2)\}_{k_2=1}^{K_2}$ będzie sekwencją elementów losowych na przestrzeni probabilistycznej $(\Omega, \mathcal{F}, \mathbb{P})$ wraz z filtracją $\mathcal{F}(m)$:

$$\mathcal{F}(m) = \sigma\left\{(\tilde{\pi}(1), b(1)), (\tilde{\pi}(2), b(2)), \dots, (\tilde{\pi}(M), b(M))\right\}. \quad (2.112)$$

gdzie $\mathbf{b}(k_2) \in \mathbf{B}$ jest zbiorem parametrów algorytmu adaptacyjnego podejmowania decyzji (2.106) traktowany jako zbiór sterowań sterowanego łańcucha Markowa.

Wówczas $\left(\psi^{pd}(\hat{\xi}(k_2), \mathbf{X}^{K_{pd}}; \psi_{PR}^s(\hat{\mathbf{a}}_2(m), \mathbf{X}^{K_s})), \mathcal{F}(m) \right)$ nazywamy sterowanym łańcuchem Markowa wraz z operatorem przejścia $\mathbf{P}(\mathbf{b})$ oraz rozkładem początkowym $\mu(0)$. W rozpatrywanym przypadku sterowany łańcuch Markowa ma zbiór operatorów przejścia $\mathbf{P}(\mathbf{b})$, określonych przez licznosc zbioru \mathbf{B} , tj.:

$$\mathbf{P}(\mathbf{b}) = \begin{bmatrix} p_{(1,1)}(\mathbf{b}) & p_{(1,2)}(\mathbf{b}) & \dots & p_{(1,H)}(\mathbf{b}) \\ p_{(2,1)}(\mathbf{b}) & p_{(2,2)}(\mathbf{b}) & \dots & p_{(2,H)}(\mathbf{b}) \\ \vdots & \vdots & \ddots & \vdots \\ p_{(H,1)}(\mathbf{b}) & p_{(H,2)}(\mathbf{b}) & \dots & p_{(H,H)}(\mathbf{b}). \end{bmatrix} \quad (2.113)$$

gdzie $p_{(i,j)}(\mathbf{b})$ reprezentuje prawdopodobieństwo przejścia z poszczególnych stanów w kolejnych krokach, dla których spełnione jest:

$$\sum_{j=1}^H p_{(i,j)}(\mathbf{b}) = 1, \quad p_{(i,j)}(\mathbf{b}) \geq 0. \quad (2.114)$$

Poszczególne elementy sterowanego łańcuch Markowa wyliczane są w następujący sposób:

$$\begin{aligned} p_{(i,j)}(k_2, k_2 + 1 | \mathbf{b}(m)) &= \mathbb{P}(s(k_2) = \psi_{PR}^{pd}(\hat{\xi}(j); \mathbf{b}(m)) | s(k_2 - 1) = \\ &= \psi_{PR}^{pd}(\hat{\xi}(i); \mathbf{b}(m)); \mathbf{b}(m) = \psi_{PR}^s(\hat{\mathbf{a}}_2(l), \mathbf{X}^{K_s})) = \\ &= \mathbb{P}(s(k_2) = \psi_{PR}^{pd}(\hat{\xi}(j); \mathbf{b}(m)) | s(1) = \psi_{PR}^{pd}(\hat{\xi}(i_1); \mathbf{b}(m)), s(2) = \\ &= \psi_{PR}^{pd}(\hat{\xi}(i_2); \mathbf{b}(m)), \dots, s(k_2 - 2) = \psi_{PR}^{pd}(\hat{\xi}(i_{k-2}); \mathbf{b}(m)), s(k_2 - 1) = \\ &= \psi_{PR}^{pd}(\hat{\xi}(i); \mathbf{b}(m)); \mathbf{b}(1) = \psi_{PR}^s(\hat{\mathbf{a}}_2(l_1), \mathbf{X}^{K_s}), \mathbf{b}(2) = \\ &= \psi_{PR}^s(\hat{\mathbf{a}}_2(l_2), \mathbf{X}^{K_s}), \dots, \mathbf{b}(m - 1) = \psi_{PR}^s(\hat{\mathbf{a}}_2(l_{m-1}), \mathbf{X}^{K_s}), \mathbf{b}(m) = \\ &= \psi_{PR}^s(\hat{\mathbf{a}}_2(l), \mathbf{X}^{K_s})). \end{aligned} \quad (2.115)$$

gdzie $\mathbf{b}(m)$ jest wybierane ze zbioru \mathbf{B} (2.103).

2.3.11 Adaptacyjne zadanie wspomaganie podejmowania decyzji z uaktualnianiem wiedzy eksperta

Opis procesu

W rozdziale 2.3.7 zaproponowano procedurę wspomaganie podejmowania decyzji dla systemu (Rysunek 2.3) ze strojonym parametrem. Celem modyfikacji głównego algorytmu (2.66) zastosowanego w rozpatrywanym zadaniu było uzupełnienie niedostatku informacji *a priori* zawartej w ciągu uczącym (2.64). W rozdziale 1 przedstawiono powody, które mogą prowadzić do trudności w wykorzystaniu zdobytej wiedzy eksperta. Opisywany proces w literaturze określa się terminem "uczenie się" [53]. Podejść do projektowania algorytmów sterowania bądź wspomagających podejmowanie decyzji można wymienić kilka. W poprzednim rozdziale 2.3.7 opisane zostało jedno z możliwych podejść tj. w głównym algorytmie wspomaganie podejmowania decyzji wektor parametrów \mathbf{b} ulega modyfikacji w trakcie trwania procesu, tak by możliwe było poprawienie uzyskiwanych wyników.

Innym możliwym sposobem pozwalającym na projektowanie systemów "uczących się" jest nie zmiana wektora parametrów algorytmu wspomaganie podejmowania decyzji ale modyfikowanie bazy wiedzy pozyskanej od eksperta (2.64).

Koncepcja ta, wykorzystywana w adaptacyjnych systemach wspomaganie podejmowania decyzji zwana jest podejściem z uaktualnianiem wiedzy [40], [42]. Uaktualnianie wiedzy w systemie odbywa się z pewnym ustalonym interwałem, który może wpływać na uzyskiwane wyniki. Po dokonaniu modyfikacji w bazie danych kolejne decyzje podejmowane są na podstawie bieżącej jej zawartości.

W pracy zaproponowano dwie wersje adaptacyjnego algorytmu wspomaganie podejmowania decyzji z uaktualnianiem wiedzy eksperta tj.:

1. Dodawanie nowych reguł, które wyznaczone są w trakcie procesu wspomaganie podejmowania decyzji;
2. Wymiana nowych reguł, które zostały wyznaczone w trakcie procesu wspomaganie podejmowania decyzji ze starszymi będącymi już w bazie wiedzy.

Powyżej podano dwa różne sposoby dokonywania zmian w bazie wiedzy. Należy również opisać sposób w jaki zaproponowany układ będzie dokonywał oceny przydatności nowych rozwiązań oraz odrzucał te, które są najmniej przydatne w omawianym procesie wspomaganie podejmowania decyzji.

Adaptacja w systemach sterowania bądź wspomaganie podejmowania decyzji może dokonywać się na dwa sposoby: z nagradzaniem i bez nagradzania [53]. W omawianej pracy zaproponowano algorytm uaktualniania bazy wiedzy bazujący na podejściu bez nagradzania. Podejście to, zwane również samouczeniem odpowiada sytuacji, gdy projektujący system dysponuje minimalną informacją *a priori* [53]. Chcąc wykorzystać zaproponowane podejście w procesie wspomaganie podejmowania decyzji należy ustalić pewien wskaźnik jakości, który zostanie wykorzystany do oceny wpływu poszczególnych elementów ciągu uczącego (2.64) bądź nowych elementów. W tym celu, można wykorzystać wskaźnik Q^{pd} (2.48) bądź (2.50).

2.3.12 Sformułowanie problemu adaptacyjnego wspomaganie podejmowania decyzji z uaktualnianiem wiedzy eksperta

Założmy, tak jak w podpunkcie 2.3.4, że dysponujemy ciągiem uczącym w postaci (2.64):

$$\mathbf{X}^{K_{pd}} = \left\{ \left(\tilde{\xi}_1, \pi_{h_1}^* \right), \left(\tilde{\xi}_2, \pi_{h_2}^* \right), \dots, \left(\tilde{\xi}_{K_{pd}}, \pi_{h_{K_{pd}}}^* \right) \right\}.$$

Do wspomaganie podejmowania decyzji w rozpatrywanym systemie (Rysunek 2.3) wykorzystano algorytm z podrozdziału 2.3.5, tj.:

$$\tilde{\pi}^*(k_2 + 1) = \psi_{PR}^{pd} \left(\hat{\xi}(k_2), \mathbf{X}^{K_{pd}}; \mathbf{b} \right).$$

Zadanie uaktualniania wiedzy zawartej w ciągu uczącym $\mathbf{X}^{K_{pd}}$ polega na sukcesywnej wymianie wiedzy w bazie, tj.:

$$\mathbf{X}^{K_{pd}}(k_2 + 1) = \mathbf{X}^{K_{pd}}(k_2). \quad (2.116)$$

2.3.13 Adaptacyjny algorytm wspomaganie podejmowania decyzji z uaktualnianiem wiedzy eksperta – wersja I

Algorytm uaktualniania wiedzy w bazie $\mathbf{X}^{K_{pd}}$ w wersji pierwszej przedstawiono w poniższych krokach:

1. Przyłóż do wejścia obiektu na stopniu drugim sekwencję scenariuszy $\{\pi(k_2)\}_{k_2=1}^{K_2^h}$. Następnie wyznacz $\{\hat{\xi}(k_2)\}_{k_2=1}^{K_2^h}$. Dla przypadku z obiektem stochastycznym 2.3.2: $\{\tilde{\xi}(k_2)\}_{k_2=1}^{K_2^h}$;

2. Wyznacz wartość wskaźnika jakości Q^{pd} dla każdej zmierzonej wartości z sekwencji $\{\hat{\xi}(k_2)\}_{k_2=1}^{K_2^h}$ albo $\{\tilde{\xi}(k_2)\}_{k_2=1}^{K_2^h}$, który opisano w sposób następujący:

$$Q^{pd} \left(\pi^*(1), \pi^*(2), \dots, \pi^*(K_2^h - 1); \hat{\xi}(1), \hat{\xi}(2), \dots, \hat{\xi}(K_2^h) \right) = \sum_{k_2=1}^{K_2^h} q^{pd}(\pi(k_2), \hat{\xi}(k_2))$$

oraz

$$Q^{pd} \left(\pi^*(1), \pi^*(2), \dots, \pi^*(K_2^h - 1); \tilde{\xi}(1), \tilde{\xi}(2), \dots, \tilde{\xi}(K_2^h) \right) = \sum_{k_2=1}^{K_2^h} q^{pd}(\pi(k_2), \tilde{\xi}(k_2)).$$

gdzie K_2^h jest długością horyzontu.

3. Z ciągu $\{\hat{\xi}(k_2)\}_{k_2=1}^{K_2^h}$ albo $\{\tilde{\xi}(k_2)\}_{k_2=1}^{K_2^h}$ wybierz ten element, dla którego wartość wskaźnika jakości Q^{pd} wyliczonego w punkcie 2. była najmniejsza;
4. Dodaj nowy element $(\hat{\xi}_{K_{pd}+1}, \pi_{h_{K_{pd}+1}}^*)$ do ciągu uczącego $\mathbf{X}^{K_{pd}}$.

Adaptacyjny algorytm wspomaganie podejmowania decyzji z uaktualnieniem wiedzy eksperta – wersja II

1. do 4. tak jak dla algorytmu;
5. W sekwencji uczącej $\mathbf{X}^{K_{pd}}$ wyszukaj element, dla którego wartość wskaźnika jakości Q^{pd} jest największa;
6. Zamień element z kroku 3. z elementem znalezionym w kroku 5.

Rozdział 3

Badania eksperymentalne

W podrozdziale 2.2.1 przedstawiono model układu neuromięśniowego, który wiązał ze sobą dwie wielkości: sygnał EMG oraz moment siły (2.8). Zależność ta została wykorzystana na pierwszym stopniu w zaproponowanym systemie (Rysunek 2.3) a jej parametry zostaną wykorzystane do oceny aktualnego stanu zdrowia pacjenta (2.8).

W rozdziale tym przedstawiono sposób przeprowadzania badań eksperymentalnych w celu pozyskania i późniejszego przetworzenia danych pomiarowych oraz analizy ich przydatności do oceny aktualnego stanu zdrowia pacjenta.


3.1 Identyfikacja modelu zespołu mięśni szkieletowych w stawie łokciowym – pierwszy stopień

3.1.1 Opis stanowiska badawczego

W celu pozyskania danych pomiarowych do identyfikacji modelu na pierwszym stopniu (podrozdział 2.2.3) przeprowadzono badania eksperymentalne. W tym celu wykorzystano gotowe stanowiska do pomiarów momentów sił generowanych w warunkach *statycznych* oraz *dynamicznych*. Pierwsze stanowisko znajdowało się w laboratorium Katedry Fizjoterapii w Medycynie Zachowawczej i Zabiegowej Akademii Wychowania Fizycznego we Wrocławiu. Przy wykorzystaniu znajdujących się tam urządzeń (Rysunek 3.1 oraz 3.2) wykonano badania zarówno w warunkach *statycznych* jak i *dynamicznych*. Drugim ośrodkiem, z którym nawiązano współpracę w celu przeprowadzenia badań był University of Iowa. Dzięki

uprzejmości pracujących tam osób udało się zgromadzić zestaw danych pomiarowych wykorzystanych następnie w zadaniu identyfikacji modelu na pierwszym stopniu.

Dzięki przeprowadzonym badaniom możliwe było dokonanie oceny przydatności zaproponowanego modelu do celów diagnostycznych.



Rysunek 3.1: Stanowisko do pomiaru momentów sił (Katedra Fizjoterapii w Medycynie Zachowawczej i Zabiegowej Akademii Wychowania Fizycznego we Wrocławiu)

Wykorzystane stanowisko w Katedrze Fizjoterapii w Medycynie Zachowawczej i Zabiegowej Akademii Wychowania Fizycznego we Wrocławiu składało się z urządzenia do pomiaru momentów sił (*Biodex System 3*) oraz urządzenia służącego do pomiarów EMG podczas wykonywanych ćwiczeń *Octopus AMT-8* firmy *Bortec*.

Zestaw urządzeń wykorzystywanych w laboratorium umiejscowionym w University of Iowa to również urządzenie *Biodex*, natomiast do pomiarów sygnałów EMG wykorzystano *Delsys Bagnoli System*.

Wykorzystane urządzenia umożliwiają jednoczesny pomiar momentów sił generowanych w warunkach *statycznych* oraz *dynamicznych*. Możliwość ta jest o tyle ważna, że ułatwia późniejsze przygotowanie danych do zadania identyfikacji.



Rysunek 3.2: Stanowisko do pomiaru momentów sił (Katedra Fizjoterapii w Medycynie Zachowawczej i Zabiegowej Akademii Wychowania Fizycznego we Wrocławiu)


Z praktycznego punktu widzenia bardzo istotną kwestią jest możliwość wykonywania powtarzalnych badań. W pracy [119] zwrócono uwagę, że nowoczesne urządzenia pozwalają na dużą powtarzalność przeprowadzanych badań. Związane jest to między innymi z konstrukcją urządzeń, które umożliwią unieruchomienie wybranych stawów. Dzięki temu eliminuje się wpływ pewnych grup mięśni, które w zaprojektowanym eksperymencie nie powinny wpływać na wypadkowy moment siły generowany przez kończynę. Inną, bardzo ważną z praktycznego punktu widzenia cechą urządzeń wykorzystanych w eksperymencie, jest możliwość ustalenia pewnych ograniczeń odnośnie prędkości wykonywanych przez badanego ruchów. Użytkownik może również dokładnie ustawić zakresy wykonywanych przez pacjenta ruchów.

Zastosowanie wykorzystanych w badaniach urządzeń jest znacznie szersze niż mógłby na to wskazywać zakres przeprowadzonych badań. Przez ostatnich kilka dekad obserwuje się wzrost zainteresowania wyspecjalizowanym sprzętem do oceny układu ruchu człowieka z różnych perspektyw. Związane jest to między innymi z szybkim rozwojem medycyny (np. patologia ruchu), ale również z

rozwojem dziedzin medycyny ściśle związanych ze sportem [119].

3.1.2 Opis eksperymentu

W podpunkcie tym dokonano opisu warunków w jakich przeprowadzano eksperymenty. Do pomiarów *elektromiopotencjałów* wykorzystano elektrody powierzch-



Rysunek 3.3: Umieszczenie elektrody nad odpowiednim mięśniem przed dokonaniem pomiaru

niowe typu *Ag/AgCl*, które umieszczono parami nad badanym mięśniem (Rysunek 3.3). Jak już wspomniano, sygnał EMG był mierzony przy wykorzystaniu specjalistycznych urządzeń. Podczas pomiarów sygnał próbkowano z częstotliwością 1000 Hz. Wielkość ta jest wystarczająca i często stosowana w badaniach eksperymentalnych. Jest to związane z tym, że sygnał EMG zawarty jest w paśmie częstotliwości od 5 Hz do 450 Hz.

Przeprowadzono badania *statyczne* i *dynamiczne*. Pierwsze z podejść związane jest z pomiarem w warunkach *izometrycznych* tj. przy zerowej prędkości kątowej. Natomiast do drugiej z grup zalicza się min. eksperyment przeprowadzony w warunkach *izokinetycznych* tj. stałej i ustalonej prędkości kątowej. Zarówno w jednym jak i w drugim przypadku ważne jest odpowiednie przygotowanie ekspe-



Rysunek 3.4: Pomiar generowanego momentu siły w warunkach dynamicznych

rymentu oraz jego późniejsze przeprowadzenie.

Próba *statyczna* polega na generowaniu przez badanego momentu siły przy ustalonym kącie. Dzięki przeprowadzonym badaniom możliwe jest określenie maksymalnych momentów sił jakie mogą zostać wygenerowane przez pacjenta w takiej próbie. Uzyskane w wyniku eksperymentu dane mogą być następnie wykorzystane do oceny aktualnego stanu zdrowia pacjenta. W rozdziale 2 wskazano na to, że wyniki właśnie takich testów mogą stanowić podstawę do planowania rehabilitacji. Nie jest to jedyny obszar zastosowań opisanej metody – może być ona również wykorzystana do badań ludzi zdrowych np. w celu oceny przydatności danej osoby do wybranej dyscypliny sportowej [119].

Druga z prób, która pozwala na określanie *charakterystyk izokinetycznych*, to próba *dynamiczna*. W badaniach tych, dokonuje się pomiaru wygenerowanej przez poruszającą się kończynę momentów sił dla ustalonej prędkości kątowej. Wykorzystane urządzenie *Biodes* umożliwia bardzo precyzyjne ustalenie prędkości przy której wykonywany będzie eksperyment. Jest to bardzo ważny element przygotowania eksperymentu – z przeprowadzonych badań wynika, że wpływa to w znaczący sposób na wartość generowanych przez daną kończynę momentów sił. W literaturze dotyczącej tematu jest to również dobrze znany fakt [119]. Dla

bezpieczeństwa badanego, ale również dla umożliwienia przeprowadzenia badań powtarzalnych, wykorzystane urządzenie umożliwia dokładne określenie granic w jakich ma być dokonywany ruch wybranej kończyny.

Warto podkreślić, że w celu zapewnienia powtarzalnych wyników w różnych eksperymentach należy zapewnić badanemu możliwość odpoczynku. Jest to jedna z kluczowych kwestii, gdyż dokonywanie badań dla zmęczonej osoby jest pozbawione sensu, a otrzymane wyniki bezużyteczne. Należy również podkreślić, że przeprowadzane badania powinny być wykonywane w warunkach maksymalnego pobudzenia [119], co jest możliwe do skontrolowania przy wykorzystaniu urządzenia *Biodex*. Zastosowanie w narzędziu badawczym urządzeń wizualnych pozwala na bieżące monitorowanie eksperymentu i odrzucanie tych prób, w których badany nie spełnił wymagań, co do warunków przeprowadzenia eksperymentu.

Na koniec tego podrozdziału dokonajmy podsumowania warunków w jakich odbywał się eksperyment:

- staw łokciowy został tak przymocowany do urządzenia, że ramię i przedramię można traktować jako *parę kinematyczną* o jednym stopniu swobody;
- eksperyment jest bierny tj. podczas badań nie ma możliwości oddziaływania na sygnał pobudzający obiekt;
- mierzonym sygnałem wejściowym jest sygnał EMG;
- mierzonym sygnałem wyjściowym jest generowany w warunkach dynamicznych lub statycznych moment siły.

3.2 Ocena wyników identyfikacji modelu zespołu mięśni szkieletowych w stawie łokciowym - pierwszy stopień

W podpunkcie 3.1.2 przedstawiono sposób dokonywania eksperymentu w zadaniu *statycznym* oraz *dynamicznym*. Zgromadzone dane wykorzystane zostaną do identyfikacji parametrów modelu opisującego zależność pomiędzy sygnałem EMG a generowanymi podczas ruchu momentami sił. W podpunkcie 3.2 przedstawiono wyniki identyfikacji modelu (2.8) w przypadku gdy do rozwiązania zadania wykorzystano dane z eksperymentu przeprowadzonego w warunkach *statycznych*. W kolejnym podpunkcie 3.2 zaprezentowano wyniki estymacji parametrów modelu dla danych uzyskanych w trakcie eksperymentu w warunkach *dynamicznych*. W ostatnim z podrozdziałów 3.2 przedstawiono wyniki dotyczące próby wykonanej w

warunkach *dynamicznych* dla wysiłku długotrwałego. W omawianym przypadku wykonanych zostało 50 zgięć i wyprostów kończyny górnej w stawie łokciowym.

Identyfikacja parametrów modelu podstawowego dla danych eksperymentalnych pochodzących z próby statycznej

W poniższym podpunkcie przedstawiono wyniki dla danych z eksperymentu *statycznego*. W eksperymencie tym badany stara się wytworzyć maksymalny moment siły przy unieruchomionym stawie. Cechą charakterystyczną próby *statycznej* jest to, że jest ona wykonywana przy zerowej prędkości kątowej. Eksperyment wykonano dla jednego ustalonego kąta pomiędzy ramieniem i przedramieniem.


Na (Rysunek 3.5) przedstawiono przykładowy zestaw danych pomiarowych tj. sygnału wejściowego (EMG) oraz wyjściowego (moment siły). Dostępne sygnały są nośnikami wielu informacji [146], które można wykorzystać w celach np. diagnostycznych. Przed przystąpieniem do tego zadania dane pomiarowe powinny zostać przetworzone tak, by były źródłem informacji ilościowej. Przedstawiony sposób pozyskiwania informacji bazujący na metodach identyfikacji i modelowania matematycznego jest tylko jednym z kilku możliwych do wykorzystania. Oprócz powyższej metody, która została opisana w pracy są również metody oparte np. na analizie widmowej sygnałów EMG.

Na (Rysunek 3.6) przedstawiono proces przetwarzania sygnału wejściowego EMG, który składa się z kilku etapów: prostowania dwupołówkowego oraz filtracji [115]. Dopiero tak przetworzony sygnał wejściowy wykorzystany jest w zadaniu identyfikacji z zastosowaniem algorytmów z podrozdziału 2.2.5.

Zamieszczone na wykresie dane (Rysunek 3.7) pokazują, że parametry modelu (2.8) zostały dobrane tak, że różnica pomiędzy sygnałem wyjściowym z modelu i obiektu jest niewielka. Należy jednak podkreślić, że uzyskane wyniki nie mogą być podstawą do określenia, które z parametrów modelu będzie można wykorzystać w zadaniu diagnostyki.

Identyfikacja parametrów sieci neuronowej oraz systemu *Takagi-Sugeno* dla danych eksperymentalnych pochodzących z próby statycznej

W podpunkcie tym przedstawiono wyniki modelowania zależności pomiędzy sygnałem EMG, a rozwijanym w stawie łokciowym momentem siły podczas próby

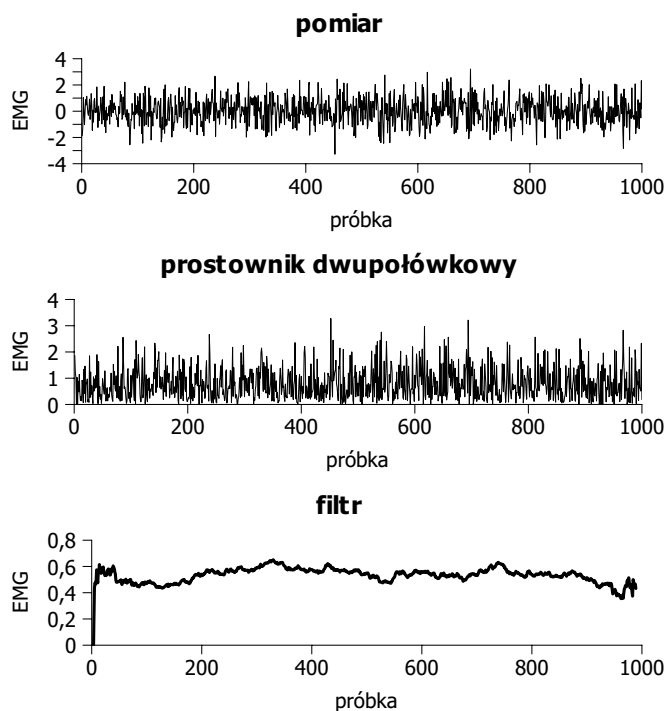


Rysunek 3.5: Dane pomiarowe do zadania identyfikacji modelu dla próby *statycznej*

statycznej. Uzyskane rezultaty dla dwuwarstwowej sieci neuronowej [125], [131] i systemu *Takagi-Sugeno* przedstawiono odpowiednio na (Rysunek 3.8 oraz 3.9). Zarówno dla modelu w postaci sieci neuronowej, jak i systemu *Takagi-Sugeno* uzyskano zadowalające wyniki, jednakże nie oznacza to, że modele te można z powodzeniem wykorzystać w zadaniu diagnostyki.

W tabelach (3.1) oraz (3.2) zamieszczono wyniki rozwiązanego zadania identyfikacji dla danych uzyskanych podczas eksperymentu *statycznego* dla ośmiu zdrowych osób. Otrzymane rezultaty zostały uśrednione. Wynika z nich, że odchylenie standardowe jest znacząco większe w porównaniu do modelu podstawowego (2.8) zarówno dla sieci neuronowej, jak i dla systemu *Takagi-Sugeno*. Zwraca uwagę fakt, że jest ono szczególnie duże dla drugiego z wymienionych systemów. Z przeprowadzonych badań wynika, że pomimo zadowalających efektów identyfikacji zarówno w jednym, jak i w drugim wypadku żaden z modeli nie nadaje się do wykorzystania w zadaniu diagnostyki.

Dla modelu podstawowego (2.8) podobną analizę, połączoną z analizą wrażliwości przeprowadzono w podrozdziale (3.3).




Rysunek 3.6: Kolejne etapy przetwarzania sygnału EMG

Tabela 3.1: Wartości wektora wag w sieci neuronowej dla ośmiu zdrowych osób biorących udział w eksperymencie

w_1		w_2		w_3		w_4	
m	std	m	std	m	std	m	std
-0.9977	1.9661	1.7404	1.085	-0.9046	1.3202	0.0784	0.1968

Identyfikacja parametrów modelu podstawowego dla danych eksperymentalnych pochodzących z próby dynamicznej

Charakter tej sekcji jest podobny do wcześniejszej, gdzie został opisany przypadek dla próby *statycznej*. W miejscu tym zaprezentowano wyniki identyfikacji parametrów modelu opisującego zależność pomiędzy sygnałem EMG, a generowanym podczas ruchu momentem siły. W tym przypadku jako dane pomiarowe wykorzystano wyniki eksperymentu przeprowadzanego w warunkach *dynamicznych* (Rysunek 3.10). Natomiast na (Rysunek 3.11) przedstawiono efekt rozwiązania zadania identyfikacji modelu podstawowego. Podobnie jak w podpunkcie




Rysunek 3.7: Efekt identyfikacji modelu podstawowego (2.8) dla danych z próby statycznej

Tabela 3.2: Wartości wektora parametrów systemu *Takagi – Sugeno* dla ośmiu zdrowych osób biorących udział w eksperymencie

σ_1		σ_2		c_1		c_2	
m	std	m	std	m	std	m	std
24.34	57.51	-39.81	57.42	4.86	4.25	5.34	4.91
b_{11}		b_{12}		b_{21}		b_{22}	
m	std	m	std	m	std	m	std
33.17	37.21	21.36	36.71	-0.94	5.42	1.25	3.90

poprzednim i tym razem wyniki identyfikacji są zadowalające. Jednakże do oceny przydatności parametrów modelu posłuży przeprowadzona w następnym podrozdziale 3.3 analiza wrażliwości.

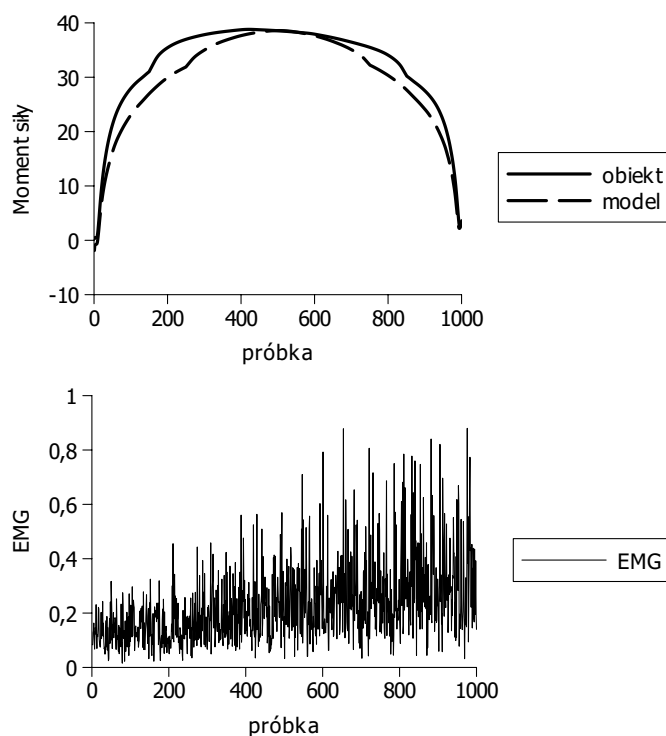
Identyfikacja parametrów modelu podstawowego dla danych eksperymentalnych pochodzących z próby dynamicznej – badanie wpływu czasu ćwiczeń na parametry modelu



Rysunek 3.8: Efekt identyfikacji modelu w postaci dwuwarstwowej sieci neuronowej dla danych z próby statycznej

W poprzednim podrozdziale przedstawiono efekt identyfikacji parametrów modelu (2.8) dla danych pochodzących z próby przeprowadzonej w warunkach dynamicznych. Opisany został tam eksperyment polegający na jednorazowym zgięciu i wyprostowaniu kończyny górnej w stawie łokciowym. Możliwe jest również przeprowadzenie eksperymentu w warunkach dynamicznych lecz dla wielokrotnie powtarzanego zadania zginania i prostowania stawu łokciowego. Przy długotrwałym wysiłku znaczącą rolę zaczyna odgrywać zmęczenie mięśni. Informacja o tym, jak dany mięsień bądź ich grupa reaguje na długotrwały wysiłek może być wykorzystana w procesie diagnostyki. Dzięki dodatkowym danym pozyskany w tym eksperymencie, możliwości trafnej oceny aktualnego stanu zdrowia badanego znacznie wzrastają.

Na kolejnych stronach – wykres (Rysunek 3.13 oraz Rysunek 3.12) – przedstawiono sygnały wejściowe (zarówno sygnał generowany przez biceps jak i triceps) i wyjściowe, które zostały zmierzone w trakcie eksperymentu w warunkach



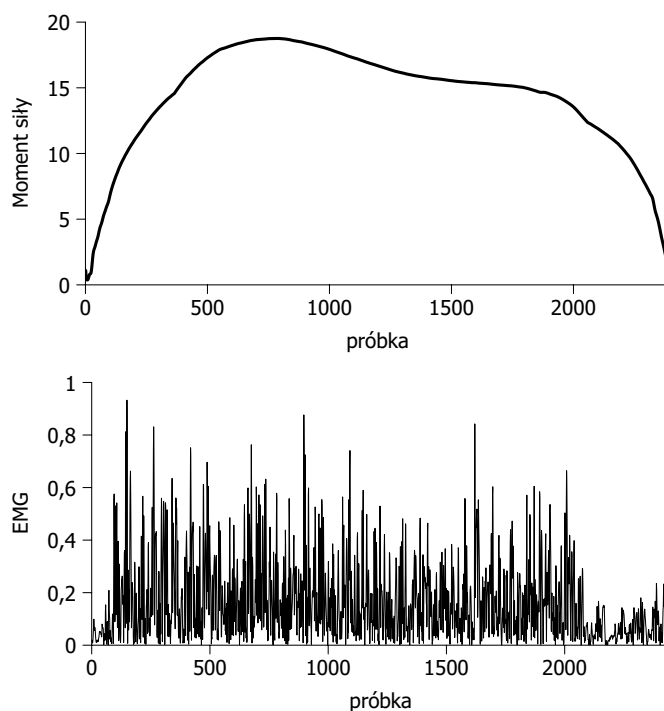
Rysunek 3.9: Efekt identyfikacji modelu w postaci systemu *Takagi – Sugeno* dla danych z próby statycznej

dynamicznych przy długotrwałym wysiłku. Analiza jakościowa danych pozwala stwierdzić, że czas trwania ćwiczeń w znacznym stopniu wpływa na wartość generowanego momentu siły.

Poniżej (Rysunek 3.14) przedstawiono wpływ czasu ćwiczeń na generowany moment siły. Z wykresu wynika, że wraz z wydłużaniem się czasu wysiłku fizycznego maksymalny moment generowany podczas jego trwania zmniejsza się [82]. Krzywa ta może być różna dla różnych osób i może być podstawą do stawiania diagnozy bądź do oceny aktualnego stanu zdrowia pacjenta.

3.3 Analiza wrażliwości modelu zespołu mięśni szkieletowych w stawie łokciowym - pierwszy stopień

Zadaniem analizy wrażliwości modelu jest oszacowanie wpływu zmian każdego z parametrów na jego zachowanie. Przeprowadzone badania, w połączeniu z rozwiązaniem zadaniem identyfikacji na pierwszym stopniu (podpunkt 3.2 oraz 3.2),



Rysunek 3.10: Dane pomiarowe do zadania identyfikacji modelu dla próby dynamicznej


Tabela 3.3: Wartości wektora parametrów \mathbf{a}_1 dla ośmiu zdrowych osób biorących udział w eksperymencie

a_{11}		a_{12}		a_{13}		a_{14}	
m	std	m	std	m	std	m	std
-0.81	0.53	1.16	0.92	-0.46	0.56	0.93	0.03


pozwalają ocenić, które z parametrów modelu należy wykorzystać w zadaniu diagnostyki.

W podpunkcie 2.2.2 przedstawiono odpowiedni zestaw zależności, które zostały wykorzystane w zadaniu oceny wrażliwości modelu na zmiany jego parametrów z wykorzystaniem danych pomiarowych. Z wykresu (Rysunek 3.15) wynika, że zmiany parametru a_{11} mają najmniejszy wpływ na wyjście modelu przy zadanym sygnale wejściowym. Z drugiej strony mamy parametr a_{14} , którego zmiany w znaczący sposób wpływają na zachowanie się sygnału wyjściowego modelu.

Przeprowadzoną analizę wrażliwości można porównać z eksperymentem, który polega na identyfikacji tego samego modelu dla różnych danych wejściowych tj.




Rysunek 3.11: Efekt identyfikacji modelu podstawowego (2.8) dla danych z próby dynamicznej




Rysunek 3.12: Dane pomiarowe (moment siły) do zadania identyfikacji modelu dla próby dynamicznej – badanie wpływu czasu ćwiczeń

pochodzących od różnych osób biorących udział w badaniach. W tej części wykorzystano dane, które zgromadzono w laboratorium University of Iowa. Z danych zamieszczonych w tabeli (3.3) jednoznacznie wynika, że parametr a_{14} nieznacznie




Rysunek 3.13: Dane pomiarowe (EMG) do zadania identyfikacji modelu dla próby dynamicznej – badanie wpływu czasu ćwiczeń

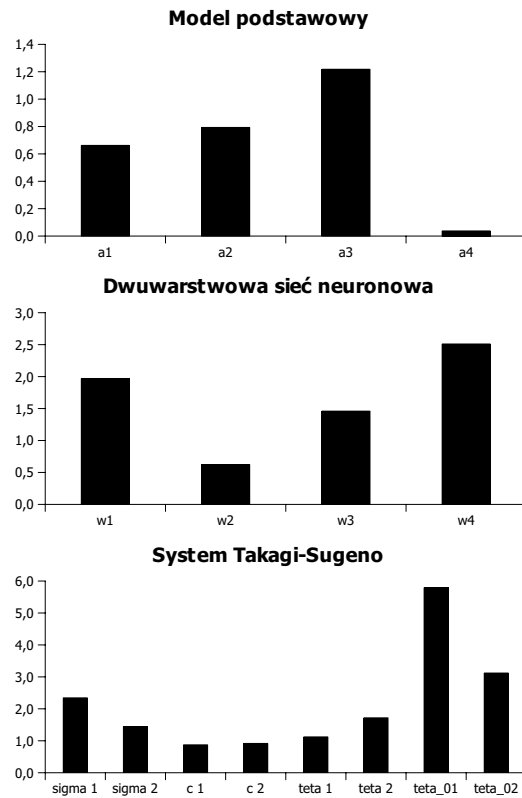


Rysunek 3.14: Wpływ czasu ćwiczeń na maksymalny moment siły generowany podczas długotrwałego ćwiczenia (zginanie). Znormalizowane wejście i wyjście

(odchylenie standardowe dla ośmiu przebadanych osób równe 0.03) zmienia się w zależności od wyników dla danego badanego. Natomiast zmiany parametrów od



Rysunek 3.15: Wrażliwość zaproponowanego modelu na zmiany jego parametrów

Rysunek 3.16: Porównanie zależności std/m dla modelu podstawowego (2.8), dwuwarstwowej sieci neuronowej oraz systemu *Takagi-Sugeno*

a_{11} do a_{13} są już znacznie większe (od 0.53 do 0.93).

W celu ułatwienia porównania wyników osiągniętych dla wykorzystanych modeli tj. modelu podstawowego (2.8), sieci neuronowej oraz systemu *Takagi-Sugeno* na (Rysunek 3.16) przedstawiono zestawienie zależności std/m wskazująca te parametry, które mogą zostać wykorzystane do diagnozowania obiektu .

Rozdział 4

Badania symulacyjne

Analiza zaproponowanego w rozdziale 2 algorytmu wspomaganie podejmowania decyzji wymaga przeprowadzenia badań symulacyjnych, które pozwolą dokonać oceny zaproponowanego rozwiązania. Ponieważ nie było możliwości wykonania dokładnych badań eksperymentalnych z pacjentami, weryfikacji opracowanych procedur dokonano przy wykorzystaniu modelu matematycznego.

W niniejszym rozdziale, bazując na odpowiednim modelu (dokładny opis zamieszczono w podrozdziale 4.1.1), zbadano wpływ zaplanowanej terapii na poprawę stanu zdrowia pacjenta.

Planując zabiegi elektroterapeutyczne dla spastyków należy wziąć pod uwagę to, że powinny być one całkowicie bezpieczne dla pacjentów a jednocześnie pomóc w poprawie stanu zdrowia pacjenta. Z badań nad zagadnieniem bezpieczeństwa elektrostymulacji zaczerpnięto przedstawiony w kolejnym podrozdziale model [56] opisujący wpływ zmęczenia mięśni szkieletowych podczas pobudzania ich impulsami elektrycznymi (ang. *Functional Electrical Stimulation*, FES). Dodatkowym ograniczeniem w stosowaniu omawianej metody jest problem szybkiego męczenia się mięśni pobudzanych impulsami elektrycznymi [56], co zostało już podkreślone we wstępie do niniejszej pracy (rozdział 2.2).

Zadaniem lekarza lub fizjoterapeuty prowadzącego rehabilitację osoby cierpiącej na spastyczność jest taki dobór sygnałów stymulujących, aby przy minimalnym zmęczeniu można było wygenerować możliwie największy i najskuteczniejszy, a przy tym bezpieczny dla pacjenta, moment siły. Bezpośredni wpływ na wartość generowanych momentów sił, przy wykorzystaniu *elektrostymulacji*, ma

częstotliwość generowanych impulsów, które doprowadzane są do mięśni przez odpowiednie elektrody.

W pewnym przedziale zwiększenie częstotliwości pobudzania jednostek motorycznych skutkuje wygenerowaniem większego momentu siły. Jest to związane ze zjawiskiem sumowania skurczów [152]. Warto podkreślić jest to, że w przypadku gdy częstość pobudzeń jest za wysoka, mięsień zaczyna reagować nie na każdy z impulsów lecz np. na co drugi lub co trzeci itp. Prowadzi to do zmniejszenia się częstości pobudzeń, przy jednoczesnym zredukowaniu wartości generowanego momentu siły i zwiększającym się zmęczeniu mięśni [152].

4.1 Badanie wpływu procesu podejmowania decyzji na parametry modelu zespołu mięśni szkieletowych – badania symulacyjne

4.1.1 Opis modelu symulacyjnego

W literaturze adresowanej do fizjoterapeutów planujących rehabilitację osób spastycznych przy wykorzystaniu elektroterapii rozpatruje się różnorodne modele pozwalające na zrozumienie procesów zachodzących w mięśniach szkieletowych. Korzyści wynikające ze stosowania modeli są wielorakie. Jedną z głównych jest możliwość wykorzystania ich do planowania ćwiczeń rehabilitacyjnych dla spastyków [124]. Innym obszarem zastosowań budowanych modeli jest wykorzystanie ich do diagnostyki medycznej. W [68] opisano sposób wykorzystania zaproponowanych modeli do oceny stopnia upośledzenia osób sparaliżowanych.

W przedstawionych w tym punkcie badaniach symulacyjnych wykorzystano zestaw równań modelujących wpływ różnych scenariuszy pobudzeń mięśni na wartość generowanego przez nie momentu siły oraz stopnia ich zmęczenia. W pracach [56], [68] oraz [103] przedstawiono kilka podejść do rozwiązania omawianego zagadnienia. Jednym z modeli, który wykorzystano w przedstawionych w dalszej części pracy badań jest model opisanego we wcześniejszym podrozdziale procesu wydzielania z siateczki sarkoplazmatycznej kolejnych porcji jonów Ca^{2+} aktywujących skurcze [152].

Wykorzystany w badaniach symulacyjnych model składa się z dwóch głównych nieliniowych równań, które w postaci różnicowej (z krokiem h) można przed-

stawić w postaci:

$$\mathcal{C}(k_2) = \mathcal{C}(k_2 - 1) + h \left(\frac{1}{\tau_c} \mathcal{T}(k_2 - 1) - \frac{\mathcal{C}(k_2 - 1)}{\tau_c} \right), \quad (4.1)$$

$$\bar{y}(k_2) = \bar{y}(k_2 - 1) + h \left(a_{11}(k_2) \frac{\mathcal{C}(k_2 - 1)}{1 + \mathcal{C}(k_2 - 1)} - \frac{\bar{y}(k_2 - 1)}{\tau_1 + \tau_2 \frac{\mathcal{C}(k_2 - 1)}{1 + \mathcal{C}(k_2 - 1)}} \right), \quad (4.2)$$

gdzie:

$$\mathcal{T}(k_2) = \sum_{w=1}^W \left(1 + (\mathcal{T}_0(k_2) - 1) \cdot \exp \left(- \frac{u_2(k_w) - u_2(k_{w-1})}{\tau_c} \right) \right) \left(\exp \left(- \frac{k_2 - u_2(k_w)}{\tau_c} \right) \right), \quad (4.3)$$

oraz trzech pomocniczych:

$$\mathcal{T}_0(k_2) = \mathcal{T}_0(k_2) + h \left(- \frac{\mathcal{T}_0(k_2 - 1) - \mathcal{T}_0^r}{\tau^f} + v^{\mathcal{T}_0} \cdot \bar{y}(k_2 - 1) \right), \quad (4.4)$$

$$a_{11}(k_2) = a_{11}(k_2 - 1) + h \left(- \frac{a_{11}(k_2 - 1) - a_{11}^r}{\tau^f} + v^{a_{11}} \cdot \bar{y}(k_2 - 1) \right), \quad (4.5)$$

$$\tau_c(k_2) = \tau_c(k_2 - 1) + h \left(- \frac{\tau_c(k_2 - 1) - \tau_c^r}{\tau^f} + v^{\tau_c} \cdot \bar{y}(k_2 - 1) \right). \quad (4.6)$$

gdzie:

$\mathcal{C}(k_2)$ – stężenie Ca^{2+} w sarkolemie w kroku (k_2) ;

τ_c – stała czasowa związana ze zmianą stężenia Ca^{2+} ;

$\mathcal{T}(k_2)$ – wielkość uwolnionej z siateczki sarkoplazmatycznej porcji Ca^{2+} w kroku (k_2) ;

$\mathcal{T}_0(k_2)$ – początkowa wielkość porcji Ca^{2+} ;

$u_2(k_w)$ – ciąg impulsów generowanych na podstawie danego scenariusza π ;

W – liczba branych pod uwagę impulsów sterujących, które pojawiły się przed chwilą (k_2) ;

$\bar{y}(k_2)$ – wartość momentu siły generowanego podczas zadanych ćwiczeń;

τ_1 i τ_2 – stałe czasowe związane z opóźnieniem powodowanym ruchem ślizgowym miozyn;

$a_{11}(k_2)$ – współczynnik skalujący, związany z modelem na pierwszym stopniu;

τ^f – stała określająca szybkość męczenia się mięśnia;

$\mathcal{T}_0^r, a_{11}^r, \tau_c^r$ – początkowe wartości zmiennych (dla niezmużonego mięśnia);

$v^{\mathcal{T}_0}, v^{a_{11}}, v^{\tau_c}$ – współczynniki skalujące dla zmiennych $\mathcal{T}_0, a_{11}, \tau_c$.

Pierwsze z przedstawionych równań (4.1) modeluje zmiany stężenia Ca^{2+} w sarkolemie ($\mathcal{C}(k_2)$ nie ma konkretnej jednostki). Pomocnicza zmienna $\mathcal{T}(k_2)$ wykorzystana jest w omawianym równaniu do modelowania procesu sumowania kolejnych skurczów Ca^{2+} [152] pod wpływem impulsów pobudzających. Natomiast drugie z równań (4.3) opisuje proces rozwijania momentu siły ($N \cdot m$) pod wpływem dochodzących do mięśni szkieletowych impulsów pobudzających.

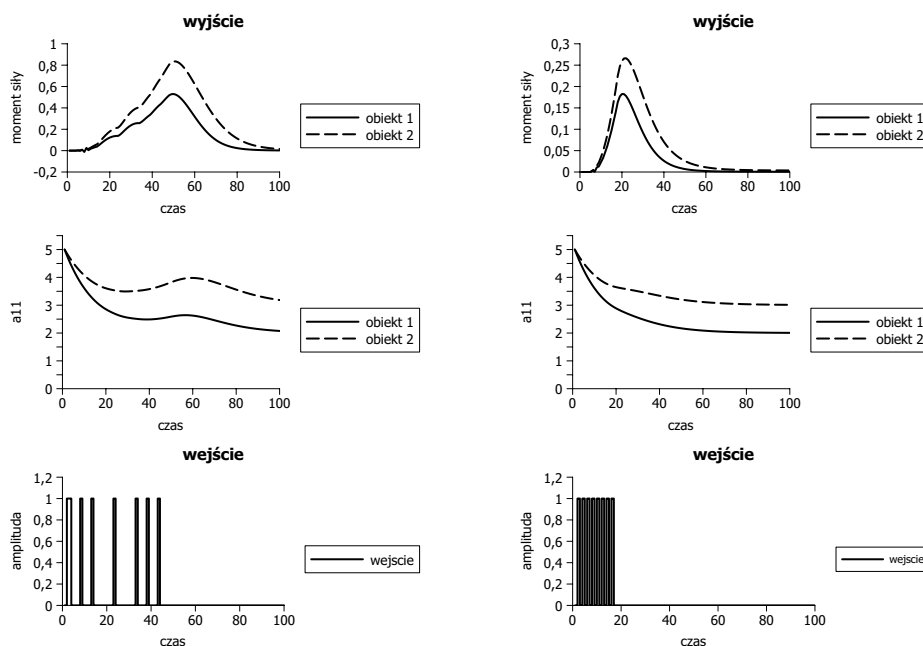
Sygnal pobudzający (4.2) wyliczany jest na podstawie opracowanych scenariuszy. Każdy z wykorzystanych scenariuszy opisuje:

- czas trwania impulsu;
- czas relaksacji;
- liczbę impulsów pobudzających.

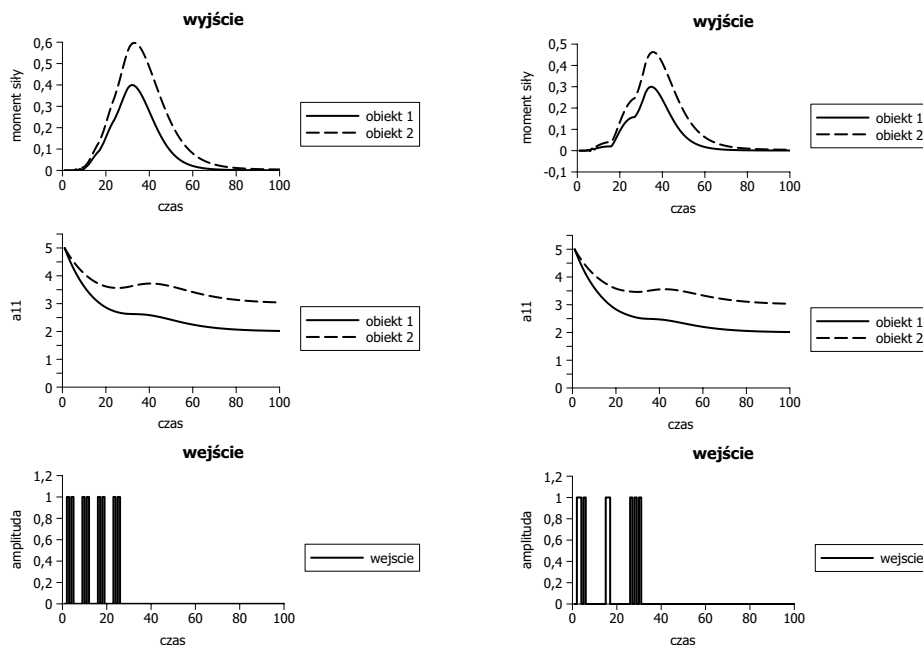
W rozdziale 2.2 na (Rysunek 2.1) przedstawiono przykładowe scenariusze pobudzeń elektrycznych, które wykorzystano w badaniach symulacyjnych (na podstawie [68]).

W przeprowadzonych badaniach symulacyjnych wykorzystano pięć scenariuszy opisujących różne schematy generowania impulsów elektrycznych. Wykorzystanie każdego z nich skutkuje inną reakcją obiektu na zadane pobudzenie.

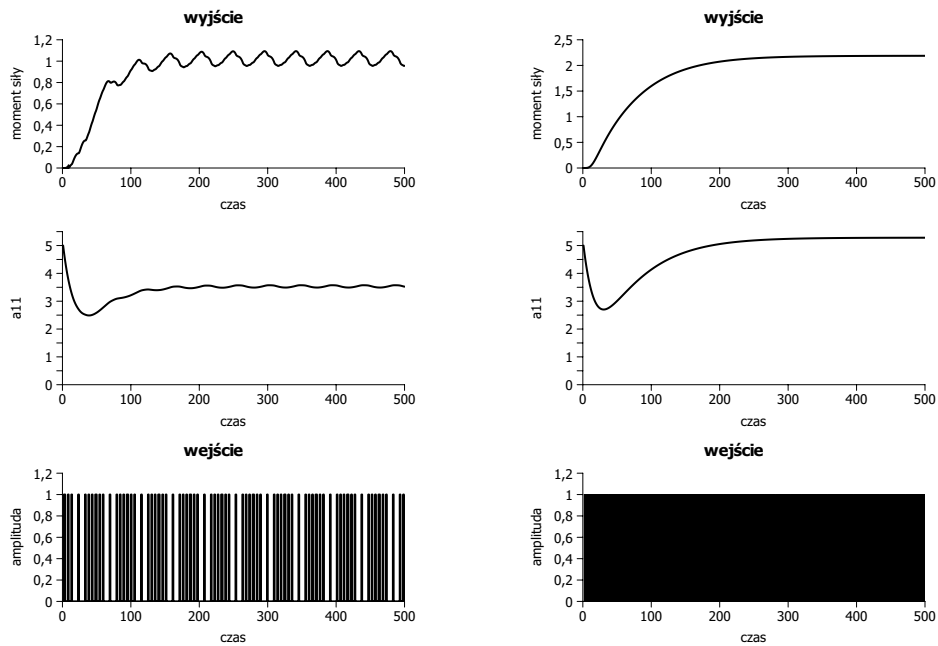
Na (Rysunek 4.1) oraz (Rysunek 4.2) przedstawiono przebiegi opisujące reakcje dwóch różnych obiektów na pobudzenie wyznaczone na podstawie czterech różnych scenariuszy. Natomiast na (Rysunek 4.3 oraz 4.4) przedstawiono przebieg procesu wspomaganego podejmowania decyzji dla pobudzeń wyznaczanych na podstawie wybranych scenariuszy sekwencji, natomiast na kolejnym dla scenariuszy wybranych w sposób losowy (Rysunek 4.5). Ostatni z przykładów miał na celu pokazanie, że przypadkowe ustalenie sekwencji impulsów pobudzających nie daje pożądanego rezultatu. Żądane efekty można osiągnąć jedynie wówczas, gdy rozwiąże się zadanie zdefiniowane w rozdziale 2.3.3, 2.3.7 oraz 2.3.11.



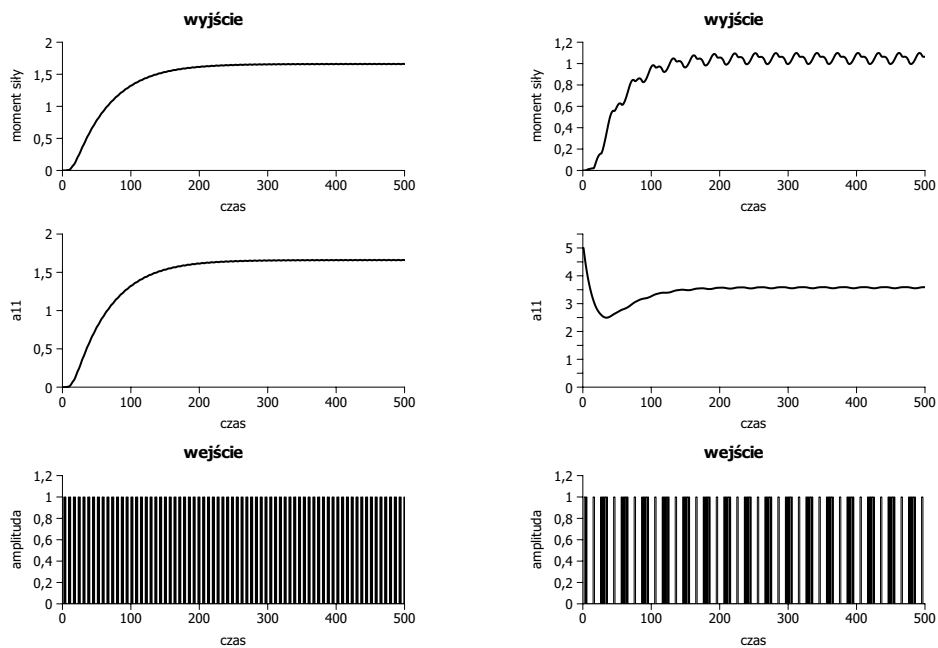
Rysunek 4.1: Przykład reakcji obiektu 1. i 2. na pojedyncze pobudzenie wyznaczone na podstawie scenariusza: 1. (z lewej) i 2. (z prawej)



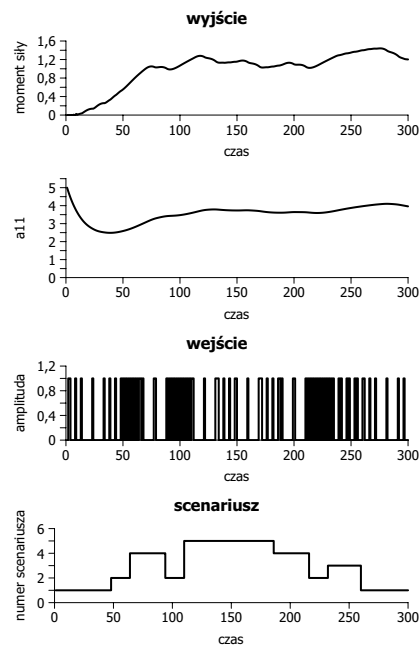
Rysunek 4.2: Przykład reakcji obiektu 1. i 2. na pojedyncze pobudzenie wyznaczone na podstawie scenariusza: 3. (z lewej) i 4. (z prawej)



Rysunek 4.3: Przykład reakcji obiektu 1. na sekwencję pobudzeń wyznaczonych na podstawie scenariusza: 1. (z lewej) i 2. (z prawej)



Rysunek 4.4: Przykład reakcji obiektu 1. na sekwencję pobudzeń wyznaczonych na podstawie scenariusza: 3. (z lewej) i 4. (z prawej)



Rysunek 4.5: Przykład reakcji obiektu 1. na sekwencję pobudzeń wyznaczonych na podstawie losowo wybranych scenariuszy od 1 do 5

4.2 Wyniki badań symulacyjnych

Porównanie wyników dla opracowanych algorytmów podejmowania decyzji

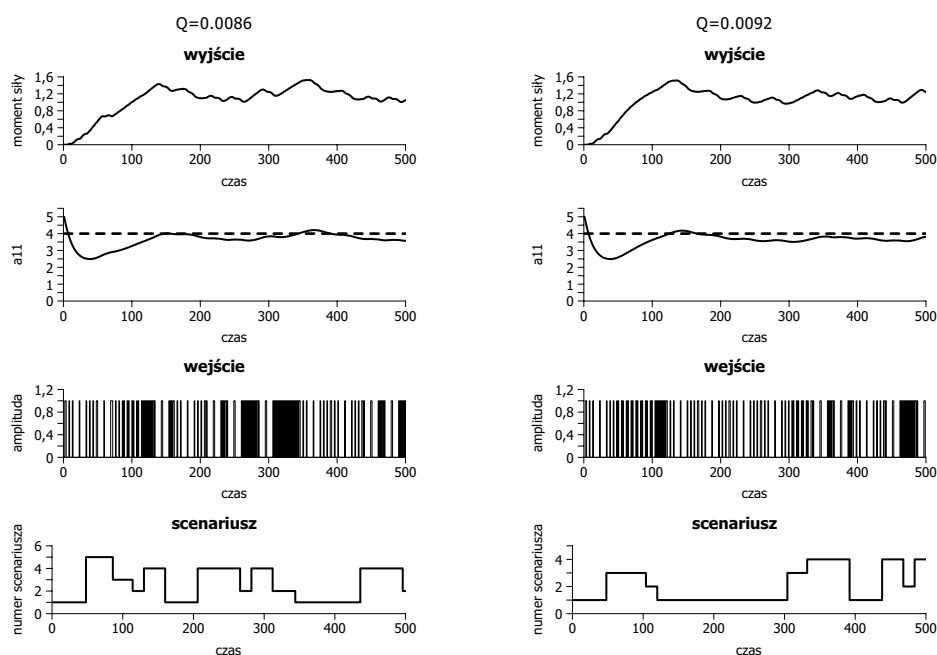
W podpunkcie tym zamieszczono rezultaty jakie otrzymano w podczas badań symulacyjnych dla trzech różnych algorytmów podejmowania decyzji, tj. z wykorzystaniem:

- metody k - NN ;
- dwuwarstwowej sieci neuronowej;
- systemu *Takagi-Sugeno*.

Badanie przeprowadzono dla dwóch różnych przypadków:

- w obecności zakłóceń pomiarowych;
- braku zakłóceń pomiarowych.

Wyniki przeprowadzonych symulacji przedstawiono na wykresach od (Rysunek 4.6, 4.7, 4.8). Jednocześnie zaznaczono, że po lewej stronie zamieszczono wyniki dla przypadku gdy nie uwzględniono zakłóceń pomiarowych, natomiast



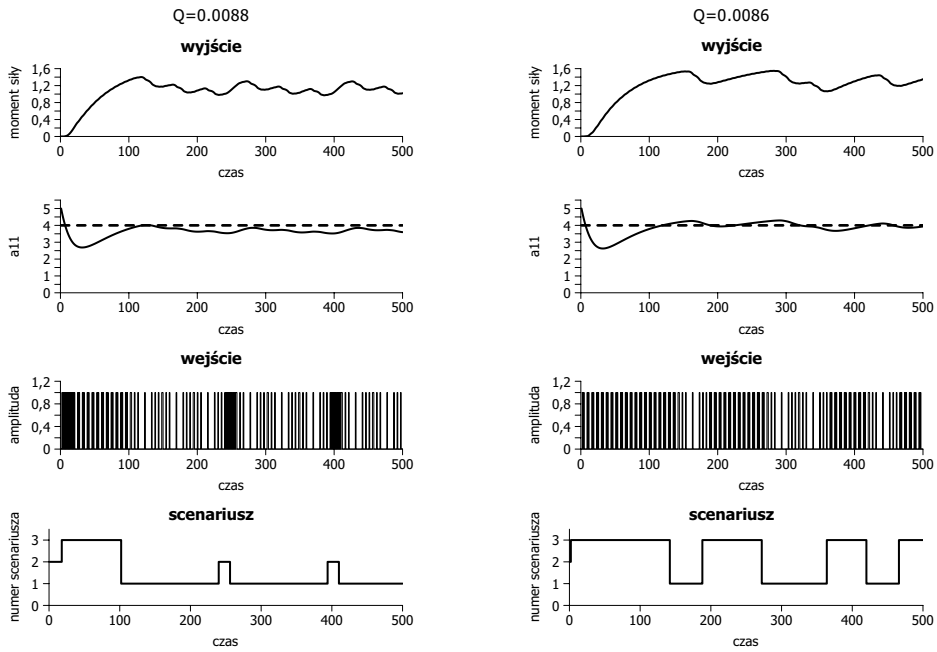
Rysunek 4.6: Algorytm oparty o k - NN : pomiar bez zakłóceń (z lewej), pomiar z zakłóceniami (z prawej)

po prawej w sytuacji gdy zakłócenia pomiarowe zostały wzięte pod uwagę.

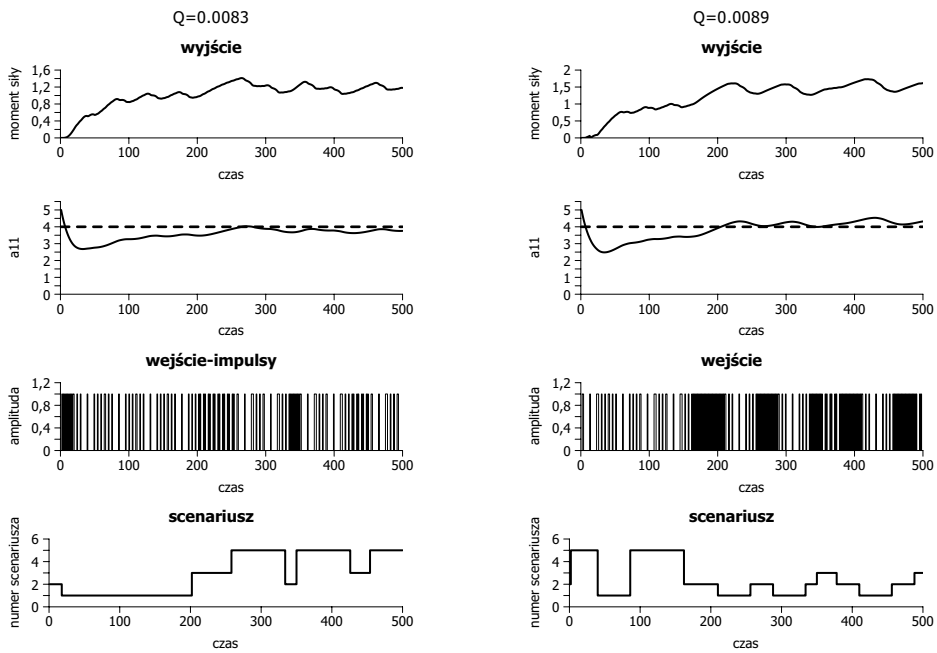
Z zamieszczonych wyników symulacji dla przypadku bez zakłóceń wynika, że najlepszy wynik (najmniejsza wartość kryterium jakości) uzyskano dla algorytmu wspomaganego podejmowania decyzji bazującego na dwuwarstwowej sieci neuronowej ($Q = 0.0086$), natomiast najslabszy wynik uzyskano dla procedury opartej o system *Takagi-Sugeno*.

Symulacje dla przypadku z zakłóceniami pomiarowymi dla każdej z procedur przeprowadzono dziesięciokrotnie a uzyskane rezultaty uśredniono. Z zamieszczonych rezultatów wynika, że kryterium jakości Q w najmniejszym stopniu uległo pogorszeniu dla systemu *Takagi-Sugeno* natomiast w największym dla procedury z wykorzystaniem algorytmu k - NN .


W zadaniach praktycznych zawsze występują zakłócenia, które mogą mieć związek z niedokładnością urządzeń pomiarowych lub zmieniających się warunków. W takiej sytuacji, najlepszym rozwiązaniem będzie wykorzystaniem algorytmu podejmowania decyzji z wykorzystaniem systemu *Takagi-Sugeno* lub rozwiązanie bazujące na sieci neuronowej.



Rysunek 4.7: Algorytm oparty o system *Takagi-Sugeno*: pomiar bez zakłóceń (z lewej), pomiar z zakłóceniami (z prawej)



Rysunek 4.8: Algorytm oparty o sieć neuronową: pomiar bez zakłóceń (z lewej), pomiar z zakłóceniami (z prawej)



Rysunek 4.9: Algorytm oparty o k - NN : pomiar bez zakłóceń (z lewej), pomiar z zakłóceniami (z prawej)

Wpływ jakości wiedzy eksperta na proces podejmowania decyzji

W zaproponowanym systemie adaptacyjnego podejmowania decyzji (Rysunek 2.3) działania podejmowane są w oparciu o wiedzę eksperta. W rozdziale tym zamieszczono wyniki symulacji dla trzech zaproponowanych procedur podejmowania decyzji i dwóch różnych zbiorów eksperta. Celem niniejszego eksperymentu symulacyjnego jest określenie, czy wiedza eksperta wpływa na otrzymane wyniki.

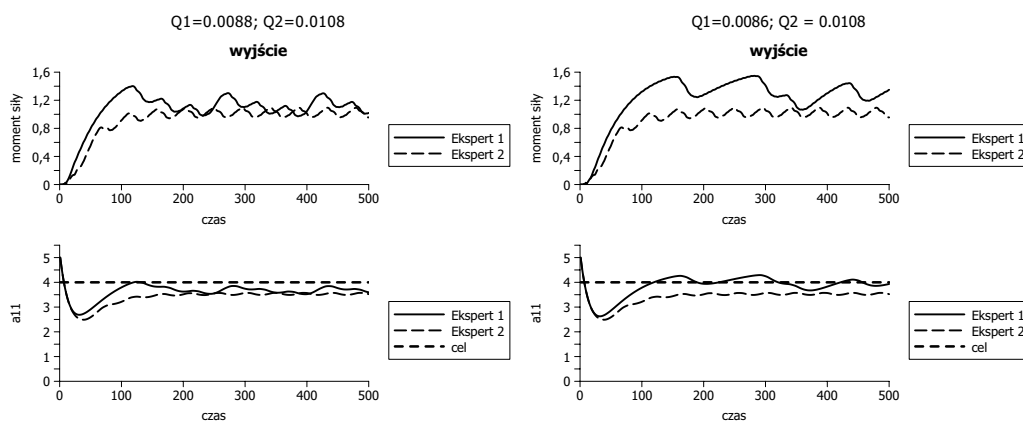
Również i w tym przypadku dokonano rozdziału na przypadek z uwzględnieniem oraz bez uwzględniania zakłóceń pomiarowych.

Analizując zamieszczone rezultaty można zauważyć, że wiedza eksperta ma duży wpływ na wyniki. Dla zbioru danych oznaczonego jako *Ekspert 2* uzyskano znacznie gorsze wyniki dla każdej z procedur niż dla zbioru *Ekspert 1*.


Zmiana zbioru uczącego w przeprowadzonych badaniach miała najmniejszy wpływ na wyniki uzyskiwane dla procedury bazującej na dwuwarstwowej sieci neuronowej. Natomiast największy dla procedury bazującej na k - NN oraz systemie *Takagi-Sugeno*.

Adaptacyjny algorytm podejmowania decyzji ze strojonym parametrem – analiza wpływu kroku strojenia

W zaproponowanym systemie adaptacyjnego podejmowania decyzji (Rysunek 2.3) wykorzystano identyfikację dwustopniową. Zastosowane podejście umożli-



Rysunek 4.10: Algorytm oparty o system *Takagi-Sugeno*: pomiar bez zakłóceń (z lewej), pomiar z zakłóceniami (z prawej)



Rysunek 4.11: Algorytm oparty o sieć neuronową: pomiar bez zakłóceń (z lewej), pomiar z zakłóceniami (z prawej)

liwia opisanie zależności pomiędzy sygnałem wejściowym $\pi(k_2)$ na drugim stopniu oraz pewnym wektorem parametrów $\mathbf{a}_1(k_2)$ modelu na pierwszym stopniu. Poprzez odpowiednie zorganizowanie eksperymentu możliwe jest zgromadzenie danych umożliwiających wyznaczenie parametrów tej zależności tj. wektora $\mathbf{a}_2(k_2)$ (podrozdział 1.5). Uzyskana wartość wektora parametrów $\mathbf{a}_2(k_2)$ może zostać wykorzystana do strojenia procedury adaptacyjnego podejmowania decyzji (podrozdział 2.3.7) tj. strojenia poprzez identyfikację (podrozdział 2.3.7).

W podrozdziale 2.3.7 zwrócono uwagę na wpływ, jaki na proces wspomagania podejmowania decyzji ma częstość dokonywania modyfikacji podstawowego

algorytmu podejmowania decyzji. Na kolejnych schematach przedstawiono wyniki przeprowadzonych symulacji.

Modyfikacji parametru procedury adaptacyjnego wspomaganie podejmowania decyzji dokonuje się na podstawie aktualnej wartości wektora parametrów $\mathbf{a}_1(k_2)$, który wyznaczany jest z wykorzystaniem algorytmów identyfikacji i odpowiednio przygotowanych danych pomiarowych. Na (Rysunek 4.12) przedstawiono dane pomiarowe (wejście i wyjście), które wykorzystane zostały w procesie identyfikacji (po lewej) oraz efekt doboru parametrów modelu na drugim stopniu (po prawej).

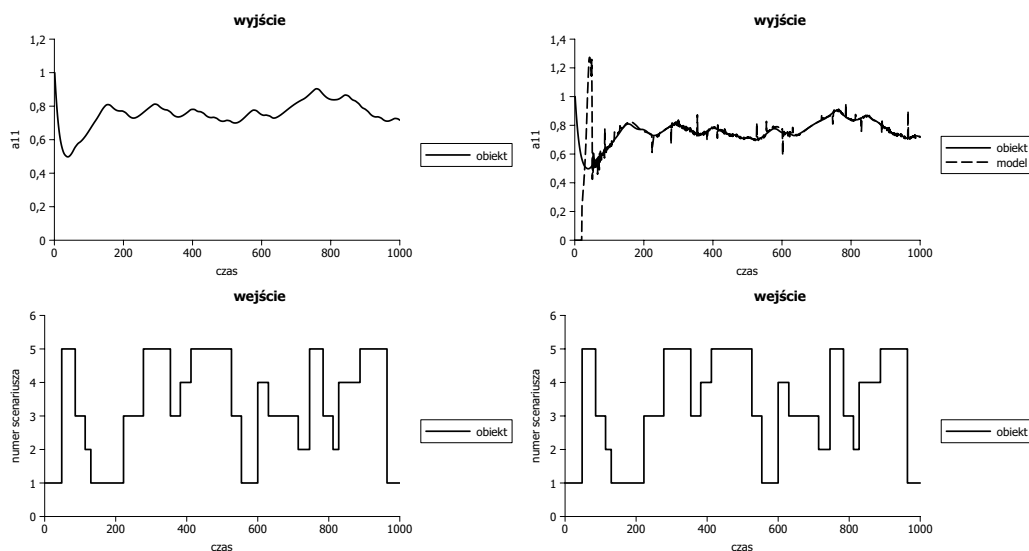
Na (Rysunek 4.13) przedstawiono wyniki badań symulacyjnych dla algorytmu przestrajającego algorytm wspomaganie podejmowania decyzji oparty o system *Takagi–Sugeno* z wykorzystaniem procedury bazującej na *NM* (*Najbliższa Średnia*) oraz z wykorzystaniem odpowiednio przygotowanej bazy wiedzy \mathbf{X}^{K_s} . Badania zostały przeprowadzone w tych samych warunkach co w podrozdziale 4.2. Można zauważyć, że zastosowanie strojonej procedury adaptacyjnego podejmowania decyzji poskutkowało zmniejszeniem wartości wskaźnika jakości zarówno dla przypadku z uwzględnieniem zakłóceń pomiarowych jak i bez ich uwzględniania. Wynika z tego, że poprawiona została efektywność omawianego procesu wspomaganie podejmowania decyzji.

Ważnym zagadnieniem, które należy wziąć pod uwagę jest sposób budowy bazy wiedzy \mathbf{X}^{K_s} wykorzystanej do strojenia algorytmu wspomaganie podejmowania decyzji. Tak jak dla algorytmu podejmowania decyzji (2.66) tak również dla jego modyfikacji zbiory uczące \mathbf{X}^K wyznaczone są na podstawie wiedzy eksperta.

Dla omawianego przypadku, w którym strojony jest algorytm bazujący na systemie *Takagi–Sugeno*, zmianie ulegają wartości parametrów $m^{(r_{PR})}$ oraz $\sigma^{(r_{PR})}$. Decyzja odnośnie zmiany wartości wymienionych parametrów podejmowana jest na podstawie aktualnej wartości wektora parametrów $\hat{\mathbf{a}}_2$ przez algorytm bazujący na procedurze najbliższa średnia *NM*.

W omawianym problemie baza \mathbf{X}^{K_s} została utworzona na podstawie pięciu różnych przebiegów sygnałów wejściowych oraz wyjściowych. Na ich podstawie wyznaczone zostały wartości odpowiednich wektorów parametrów $\hat{\mathbf{a}}_2$ oraz wartości parametrów $m^{(r_{PR})}$ oraz $\sigma^{(r_{PR})}$ systemu *Takagi–Sugeno*, który został wykorzystany w procesie wspomaganie podejmowania decyzji.

Oczywiście na wyniki wpływa również częstość dokonywania modyfikacji parametrów adaptacyjnej procedury podejmowania decyzji. Na (Rysunek 4.14)



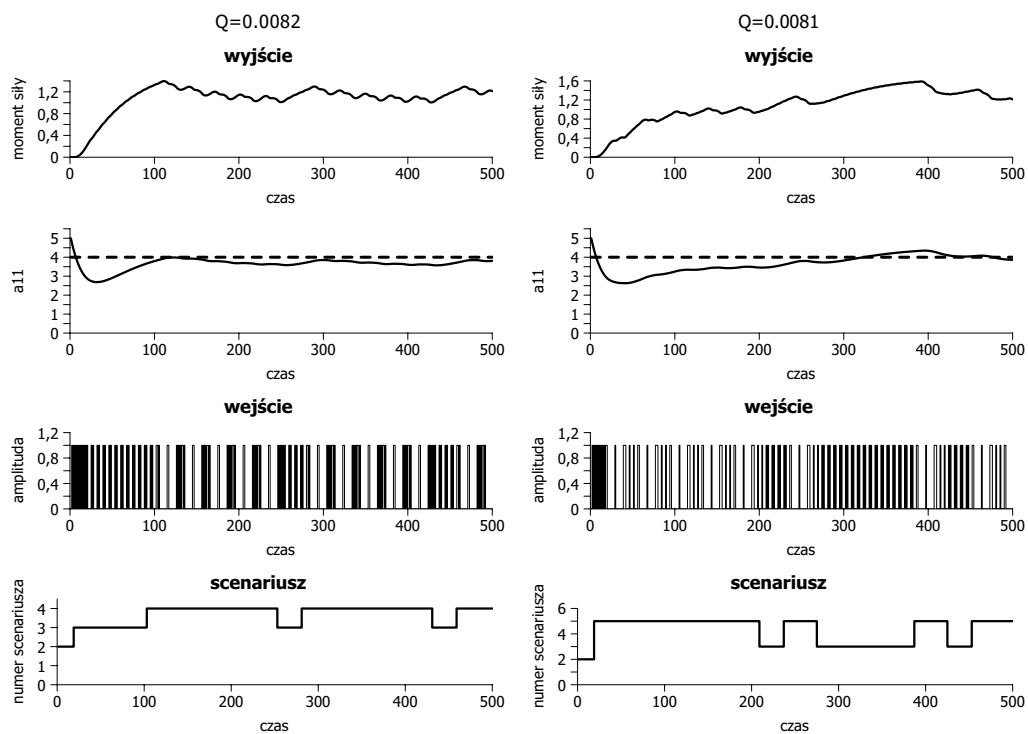
Rysunek 4.12: Pomiar sygnału wejściowego (na dole, po lewej) i wyjściowego (na górze, po lewej) dla zadania identyfikacji na 2. stopniu oraz wynik identyfikacji dla modelu procesu na 2. stopniu (po prawej)

przedstawiono zmiany wartości wskaźnika jakości Q od częstości modyfikacji parametrów algorytmu podstawowego.


Adaptacyjny algorytm podejmowania decyzji z uaktualnianiem bazy wiedzy eksperta

W podpunkcie 2.3.11 zaproponowana została zmodyfikowana procedura adaptacyjnego wspomaganie podejmowania decyzji z uaktualnianiem wiedzy eksperta. W podrozdziale tym przedstawiono wyniki badań symulacyjnych dla omawianego algorytmu w dwóch opracowanych wariantach (podrozdział 2.3.13). W głównej procedurze adaptacyjnego algorytmu wspomaganie podejmowania decyzji zastosowano system *Takagi-Sugeno*. Natomiast podprocedura wykorzystywana do aktualizacji wiedzy eksperta o wspomaganie podejmowania decyzji w omawianym systemie została opisana w podpunkcie 2.3.13.

Koncepcja zaproponowanych algorytmów modyfikujących bazę wiedzy polega na generowaniu nowych elementów dołączanych do już istniejących na podstawie danych zdobytych w trakcie trwania procesu wspomaganie podejmowania decyzji (wariant I). Wariant II różni się od pierwszego jedynie tym, że liczba reguł w bazie nie zmienia się co jest spowodowane zamianą nowych elementów z tymi, które



Rysunek 4.13: Strojonny algorytm podejmowania decyzji oparty o system *Takagi-Sugeno* i procedurę *NM*: pomiar bez zakłóceń (z lewej), pomiar z zakłóceniami (z prawej)



Rysunek 4.14: Wpływ częstości strojenia na jakość procesu wspomagania podejmowania decyzji dla strojonego algorytmu podejmowania decyzji opartego o system *Takagi-Sugeno* i procedurę *NM*

już są w bazie wiedzy.

Na (Rysunek 4.7) przedstawiono przebieg procesu dla pewnego obiektu z wykorzystaniem adaptacyjnego algorytmu wspomaganie podejmowania decyzji bazującego na systemie *Takagi–Sugeno*. Uzyskane wyniki różnią się od siebie w zależności od tego, czy informacja wykorzystana w procesie wspomaganie podejmowania decyzji jest zakłócona czy też nie. Na przedstawionym wykresie można zauważyć, że uzyskany wynik dla sytuacji idealnej (bez zakłóceń) jest lepszy od tej, w której do wspomaganie podejmowania decyzji wykorzystano dane zakłócone.

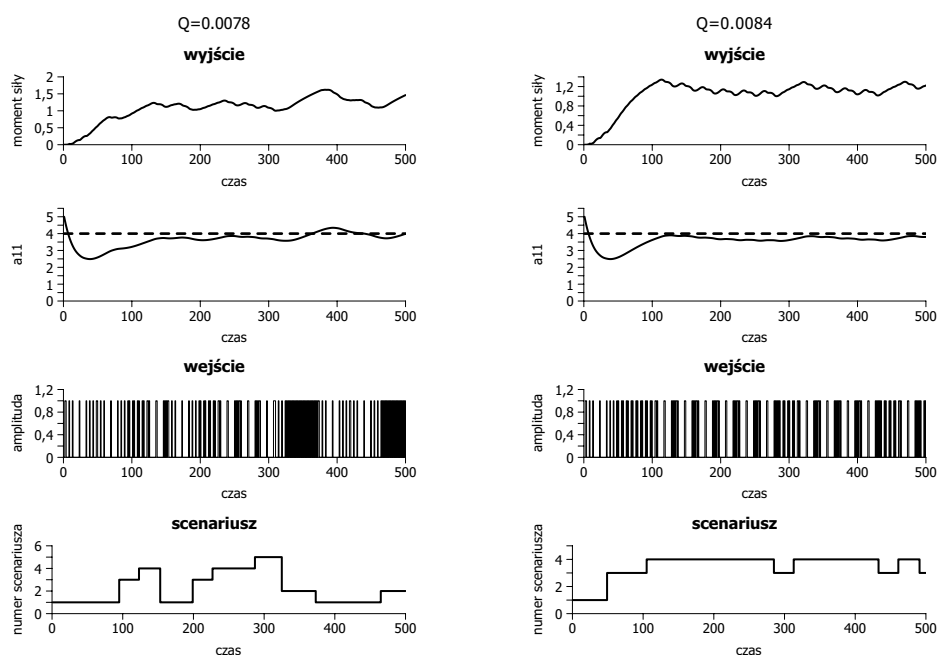
Na (Rysunek 4.15 oraz 4.16) przedstawiono wyniki symulacji dla zmodyfikowanego adaptacyjnego algorytmu wspomaganie podejmowania decyzji z podprocedurą uaktualniania wiedzy w wariancie I i II.

Zarówno dla wariantu pierwszego jak i drugiego jakość procesu wspomaganie podejmowania decyzji ulega poprawie. Różnica jest zauważalna zarówno w sytuacji idealnej (bez zakłóceń) jak również wówczas, gdy dane pomiarowe są zakłócone. Z przedstawionych wyników badań symulacyjnych wynika, że wykorzystanie algorytmów uaktualniających wiedzę eksperta o wspomaganie podejmowania decyzji w zaproponowanym systemie prowadzi do poprawy uzyskiwanych wyników. Należy podkreślić, że poprawa wyników następuje po zastosowaniu dodatkowych procedur z którymi związane są dodatkowe obliczenia.

Metody predykcyjnego podejmowania decyzji

W celu porównania otrzymanych wyników dla adaptacyjnego algorytmu podejmowania decyzji z wykorzystaniem procedur rozpoznawania obrazów w bieżącym podrozdziale przedstawiono wyniki dla innej metody wspomaganie podejmowania decyzji – bazującej na modelu.

Podejście to, które w literaturze anglojęzycznej określane jest terminem *MPC* (*ang. Model Predictive Control*) polega na optymalizacji w każdym takcie sterowania pewnej funkcji kryterialnej zdefiniowanej na skończonym horyzoncie [61], [78], [149]. Cechą charakterystyczną jest to, że horyzont ten jest przesuwany krok po kroku [149].



Rysunek 4.15: Adaptacyjny algorytm podejmowania decyzji oparty o system *Takagi-Sugeno* z aktualizacją wiedzy eksperta – wariant I: pomiar bez zakłóceń (z lewej), pomiar z zakłóceniami (z prawej)

Metoda przeglądu zupełnego

Rozdział ten zawiera wyniki symulacji dla metody predykcyjnego wspomagania podejmowania decyzji z wykorzystaniem przeglądu zupełnego do optymalizacji funkcji kryterialnej. Warto podkreślić, że metoda przeglądu zupełnego została wykorzystana ponieważ zbiór dostępnych scenariuszy jest niewielki a horyzont predykcji krótki.

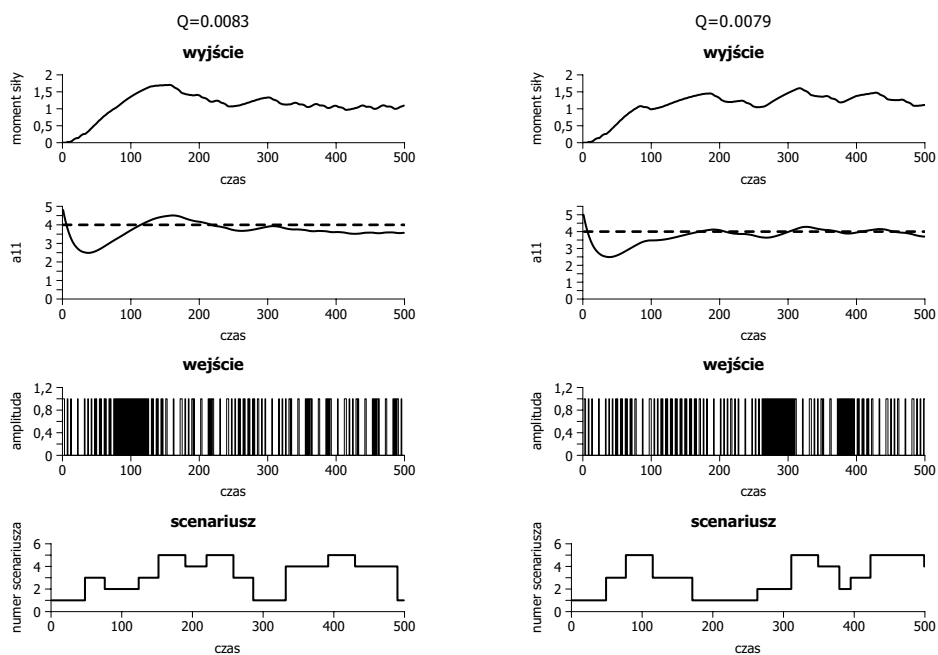
Na (Rysunek 4.18 oraz 4.17) przedstawiono wyniki dla przypadku bez uwzględniania zakłóceń pomiarowych, natomiast na (Rysunek 4.19 oraz 4.20) dla przypadku z zakłóceniami pomiarowymi.

Badania wykonano dla dwóch przypadków:

- horyzont = 1;
- horyzont = 3.


Uzyskane wyniki z badań symulacyjnych zamieszczono na wykresach (Rysunek 4.19 oraz 4.18).

W celu porównania otrzymanych wyników dla zastosowanych procedur na

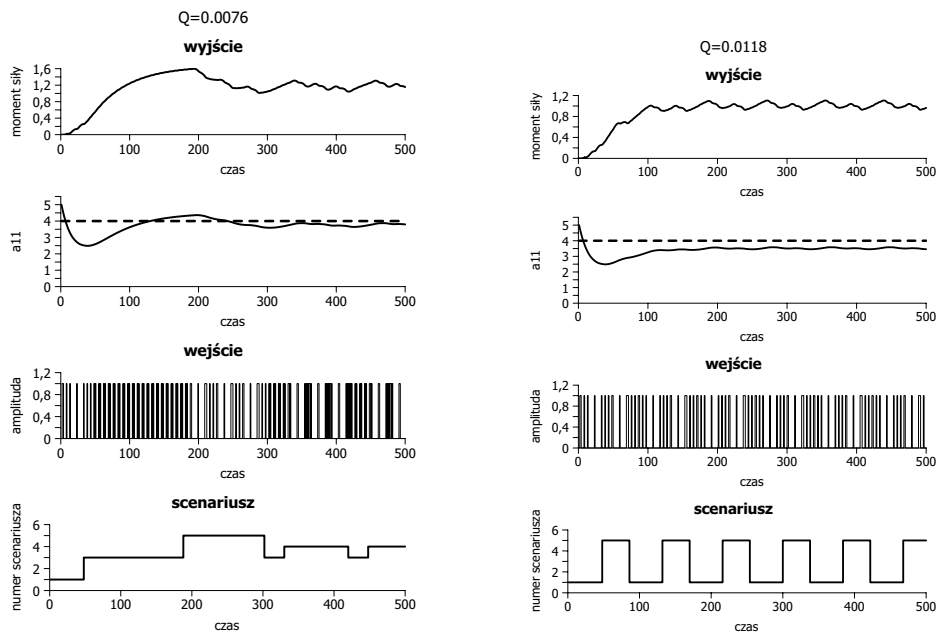


Rysunek 4.16: Adaptacyjny algorytm podejmowania decyzji oparty o system *Takagi-Sugeno* z aktualizacją wiedzy eksperta – wariant II: pomiar bez zakłóceń (z lewej), pomiar z zakłóceniami (z prawej)


(Rysunek 4.21) zestawiono wyniki dla przypadku bez i z zakłóceniami.



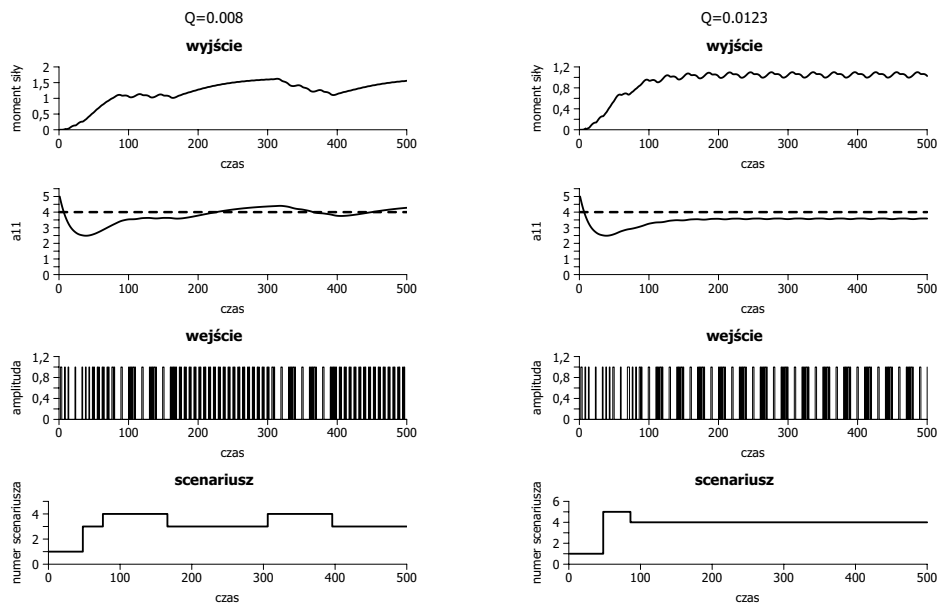
Rysunek 4.17: Wpływ kroku predykcji dla metody predykcyjnego wspomagania podejmowania decyzji (horyzont = 1, 2, 3, 4, 5; pomiar bez zakłóceń)




Rysunek 4.18: Predykcyjne wspomaganie podejmowania decyzji oparte o metodę przeglądu zupełnego (pomiar bez zakłóceń): horyzont = 3 (z lewej), horyzont = 1 (z prawej)



Rysunek 4.19: Wpływ kroku predykcji dla metody predykcyjnego wspomagania podejmowania decyzji (horyzont = 1, 2, 3, 4, 5; pomiar z zakłóceniami)



Rysunek 4.20: Predykcyjne wspomaganie podejmowania decyzji oparte o metodę przeglądu zupełnego (pomiar z zakłóceniami): horyzont = 3 (z lewej), horyzont = 1 (z prawej)



Rysunek 4.21: 1 - Algorytm dokładny; 2 - Algorytm oparty o system *Takagi-Sugeno*; 3 - Algorytm oparty o system *Takagi-Sugeno* z strojeniem; 4 - Algorytm oparty o system *Takagi-Sugeno* z aktualizacją wiedzy – wariant I; 5 - Algorytm oparty o system *Takagi-Sugeno* z aktualizacją wiedzy – wariant II. Wyniki dla przypadku bez zakłóceń (z lewej) oraz dla przypadku z zakłóceniami (z prawej)

Rozdział 5

Podsumowanie i wnioski

5.1 Oryginalny wkład pracy w dziedzinie identyfikacji dwustopniowej i adaptacyjnego wspomaganie podejmowania decyzji

W pracy podjęto problem opracowania metodyki tworzenia algorytmów wspomagających podejmowanie decyzji z wykorzystaniem podejścia dwustopniowego w zadaniu identyfikacji modelu obiektu dynamicznego. Przyjęta metodologia związana z problematyką wykorzystania analizy systemowej tj. modelowania, identyfikacji oraz rozpoznawania obiektów posłużyła jako narzędzie do rozwiązania problemu wspomaganie procesu rehabilitacji osób cierpiących na spastyczność.

Opisane powyżej zadanie planowania rehabilitacji jest genezą pracy i stał się podstawą do opracowania systemu wspomaganie podejmowania decyzji.

Jednym ze sposobów doboru zestawu impulsów pobudzających jest wykorzystanie modelowania matematycznego, identyfikacji oraz procedur rozpoznawania obiektów. Zaproponowane podejście związane jest ze specyfiką zadania, które zostało w pracy opisane tj. celem jest taka zmiana parametrów obiektu, by osiągnęły one pożądane wartości charakteryzujące sprawny obiekt. Ponieważ parametry charakteryzujące obiekt, na których wartość należy wpływać w procesie podejmowania decyzji, nie można zmierzyć bezpośrednio, w opracowanym systemie zaproponowano rozwiązanie bazujące na podejściu z identyfikacją dwustopniową. Na schemacie (Rysunek 2.3) przedstawiono strukturę zaproponowanego systemu wspomagającego podejmowanie decyzji w procesie planowania rehabilitacji osób

cierpiących na spastyczność.

W opracowanym systemie wspomagającym podejmowanie decyzji z modelem układu neuromięśniowego uwzględniającego wpływ rehabilitacji wskazano dwustopniowy obiekt identyfikacji. Pierwszy stopień w opisanym problemie pełni funkcję pomocniczą – umożliwia wyznaczanie parametrów modelu obiektu, które wykorzystane będą w zadaniu wspomagania podejmowania decyzji. Zastosowanie powyższego podejścia podyktowane zostało tym, że nie ma możliwości bezpośredniego wyznaczenia wartości parametrów obiektu. Natomiast zastosowanie podejścia dwustopniowego pozwala na pośrednie ich wyznaczenie.

Na podstawie przeprowadzonej analizy wrażliwości oraz badań eksperymentalnych określono przydatność parametrów zaproponowanego modelu do wykorzystania w zadaniu diagnostyki tj. poprzez ocenę bieżącej wartości parametrów z ich wartościami pożądanymi.

Dysponując informacją o aktualnym stanie obiektu tj. rozwiązując powyżej opisane zadanie diagnostyki, możliwe jest dokonanie wyboru scenariusza. W tym celu, w omawianym systemie, zaproponowano algorytm wspomagający podjęcie opisanej decyzji. W pracy dokonano sformułowania zadania wyboru scenariusza i wskazano sposoby jego rozwiązania. Ponieważ czas potrzebny na znalezienie dokładnego rozwiązania powyższego problemu może być nieakceptowalnie długi w opracowaniu zaproponowano przybliżony algorytm wspomagający podejmowanie decyzji.

Zaproponowane rozwiązanie bazuje na algorytmach rozpoznawania obrazów. W pracy przebadano trzy różne algorytmy: k najbliższych sąsiadów, dwuwarstwową sieć neuronową oraz system neuronowo-rozmyty typu Takagi-Sugeno. Na potrzeby badań testowych zaproponowany został model symulacyjny pozwalający ocenić wpływ zaproponowanych algorytmów wspomagających podejmowanie decyzji na parametry modelu. Dokonano również formalnej analizy zaproponowanego adaptacyjnego algorytmu podejmowania decyzji.

Działanie zaproponowanych procedur wyboru scenariusza dla opracowanego systemu można polepszyć poprzez wykorzystaniem modelu dwustopniowego. W opisywanej pracy, bazując ponownie na algorytmach rozpoznawania obiektów oraz wiedzy eksperta, opracowano zmodyfikowaną procedurę wyboru scenariusza. Skuteczność zmodyfikowanych procedur również została oceniona w przeprowadzonych badaniach symulacyjnych.

Działanie zaproponowanego systemu można polepszyć nie tylko poprzez mo-

dyfikację algorytmu wyboru scenariusza ale również poprzez uzupełnianie bazy wiedzy wykorzystanej w procesie wspomagania podejmowania decyzji.

W pracy zaproponowano algorytm wyboru scenariusza z wykorzystaniem procedur modyfikujących zawartość bazy wiedzy. Podejście to uzasadniono tym, że w trakcie trwania procesu wspomagania podejmowania decyzji można dokonywać oceny wpływu poszczególnych scenariuszy na obiekt co może stać się podstawą do modyfikacji bazy wiedzy. W pracy zaproponowano dwa warianty procedury modyfikującej zawartość bazy wiedzy:

-- z dodawaniem nowych elementów do bazy;

-- z zamianą nowych elementów z istniejącymi,

które będąc w bazie zostały ocenione w trakcie trwania procesu jako mało przydatne.

Również i w tym przypadku dokonano serii badań z wykorzystaniem opracowanego modelu symulacyjnego, które pozwoliły ocenić efektywność zaproponowanych procedur.

W celu oceny wartości diagnostycznej parametrów – do oceny aktualnego stanu zdrowia pacjenta – zaproponowanego modelu wykonano badania eksperymentalne, które pozwoliły na zgromadzenie odpowiednich danych pomiarowych. W tym celu wykorzystano gotowe stanowiska do pomiarów momentów sił i sygnałów EMG generowanych w warunkach statycznych oraz dynamicznych. Pierwsze stanowisko znajdowało się w laboratorium Katedry Fizjoterapii w Medycynie Zachowawczej i Zabiegowej Akademii Wychowania Fizycznego we Wrocławiu. Drugim ośrodkiem, z którym nawiązano współpracę w celu przeprowadzenia badań był University of Iowa. Dzięki uprzejmości pracujących tam osób udało się zgromadzić zestaw danych pomiarowych wykorzystanych następnie w zadaniu identyfikacji modelu na pierwszym stopniu.

Podsumowując, w wyniku postawionego celu pracy:

1. Zaproponowano algorytmy wyboru scenariusza na podstawie analizy parametrów modelu zespołu mięśni szkieletowych. W tym celu wykorzystano:

– algorytmy identyfikacji;

– algorytmy rozpoznawania.

2. Zaproponowano modyfikację opracowanych algorytmów wyboru scenariusza z wykorzystaniem wiedzy eksperta oraz modelu na drugim stopniu;

3. Pokazano możliwość wykorzystania zaproponowanych algorytmów wyboru scenariusza oraz ich modyfikacji w procesie rehabilitacji osób cierpiących na spastyczność. W szczególności opracowano dwustopniowy model i na podstawie analizy wrażliwości wskazano przydatność w zadaniu wyboru scenariusza;
4. Opracowano algorytmy identyfikacji dwustopniowego modelu układu mięśni szkieletowych z uwzględnieniem procesu rehabilitacji;
5. Opracowano również model symulacyjny pozwalający na badanie wpływu zaproponowanych algorytmów wyboru scenariusza i ich modyfikacji na parametry modelu pod wpływem zaplanowanej rehabilitacji z wykorzystaniem elektrostymulacji.

Część wyników, które zostały opisane w pracy opublikowano w następujących pracach: [21], [23], [22], [18], [26], [24], [17], [20], [19], [27], [31], [25], [30], [28], [29].

5.2 Proponowane kierunki przyszłych badań

Przedstawione podejście do rozwiązania przedstawionego na początku pracy medycznego problemu przy wykorzystaniu metod analizy systemowej ma również swoje wady. Ograniczenia współczesnych systemów komputerowych zmuszają projektantów do budowania uproszczonych modeli. Z jednej strony podejście takie jest pożyteczne, gdyż pozwala na tworzenie modeli czy też projektowanie systemów problemowo zorientowanych [148]. Podejście takie jest bardzo przydatne chociażby dlatego, że pozwala na dokładny opis lub wyjaśnienie pewnego zjawiska lub procesu. Z drugiej strony, bardzo uproszczone modele rzeczywistości mogą okazać się niewystarczające. Nawiązując do jednego z problemów pracy, zastosowany model opisujący zależność pomiędzy sygnałami EMG i momentem siły może okazać się mało dokładny np. na potrzeby projektowania *neuroprotez* bądź modelowania ruchów ludzkiej sylwetki na potrzeby współczesnych technologii multimedialnych. Wówczas jedynym wyjście jest próba rozbudowy, a co z tym się wiąże, zwiększenia stopnia skomplikowania modelu.

Przyszłe badania nad modelami układu mięśniowego nie są jedynym kierunkiem dalszego rozwoju, które wynikają z tematyki poruszonej w pracy.

Możliwe kierunki rozwoju zaproponowanych w pracy rozwiązań mogą być ściśle związane z opisanym adaptacyjnym systemem wspomaganie podejmowania decyzji.

W pracy zaproponowane algorytmy wspomaganie podejmowania decyzji zostały oparte o procedury rozpoznawania obrazów. Nie jest to jedyny możliwy sposób rozwiązania zadania wspomaganie podejmowania decyzji. Koncepcją, która może być również wykorzystana w opisanym problemie podejmowania decyzji, jest podejście *relacyjne* [33]. Warto podkreślić, że podejście to można również wykorzystać do opisu zależności pomiędzy sygnałami wejściowymi i wyjściowymi [33], [166]. Może to prowadzić do opracowania relacyjnych modeli zależności pomiędzy odpowiednimi sygnałami zarówno na pierwszym jak i drugim stopniu.

Innym kierunkiem przyszłych badań nad możliwością rozwoju zaproponowanego systemu może być wykorzystanie teorii systemów szarych (*ang. Grey System, GS*). Powyższe podejście, które zostało opracowane w latach osiemdziesiątych w Chinach jest bardzo efektywną metodą do modelowania i prognozowania szeregów czasowych [45].

Teoria ta znalazła szerokie zastosowanie w aplikacjach nie tylko technicznych ale również z zakresu nauk społecznych czy ekonomicznych [45]. Jest ona szczególnie użyteczna wówczas, gdy dysponujemy niewielką ilością informacji, która dodatkowo może być niepewna [138].

Teorię systemów szarych w zaproponowanym adaptacyjnym systemie wspomaganie podejmowania decyzji można wykorzystać zarówno do modelowania procesów, obiektów jak również w zadaniu diagnostyki i wspomaganie podejmowania decyzji.

Innym obszarem, na którym zaproponowane rozwiązanie może być rozwijane, związane jest w sposób bezpośredni z zastosowaniami praktycznymi.

Opisanym w pracy przykładem wykorzystania adaptacyjnego systemu wspomaganie podejmowania decyzji z identyfikacją dwustopniową i wykorzystaniem wiedzy eksperta jest problem planowania i wspomaganie podejmowania decyzji w procesie rehabilitacji osób cierpiących na spastyczność. Możliwe jest również podjęcie badań nad zastosowaniem zaproponowanego podejścia w zadaniach z zakresu nie tylko medycyny, ale również nauk technicznych tj. z zakresu robotyki, planowania produkcji oraz ekonomii.

Bibliografia

- [1] A. M. Abdel Ghany. *Two-stage identification algorithms and their application to computer adaptive control*, volume 1 of *PRE*. Raporty Inst. Ster. Tech. Syst. PWroc., 1994. [cytowanie na str. 13]
- [2] M.A. Ajzerman, E.M. Brawerman, and Rozonoer L.I. *Rozpoznawanie obrazów. Metoda funkcji potencjalnych*. WNT, 1976. [cytowanie na str. 59]
- [3] K.J. Astrom. *Introduction to Stochastic Control Theory*. Dover Publications, 2006. [cytowanie na str. 43]
- [4] K.J. Astrom, J.J. Anton, and K.E. Arzen. Expert control. *Automatica*, 22(3):277 – 286, 1986. [cytowanie na str. 43]
- [5] K.J. Astrom and B. Wittenmark. *Adaptive Control*. Prentice Hall, 1994. [cytowanie na str. 9, 43, 65]
- [6] M. Athans and P.L. Falb. *Sterowanie optymalne*. WNT, 1969. [cytowanie na str. 28]
- [7] R. Babuska, M. R. Damen, C. Hellinga, and H. Maarleveld. Intelligent adaptive control of bioreactors. *Journal of Intelligent Manufacturing*, 14(2):255 – 265, 2003. [cytowanie na str. 66]
- [8] R. Babuska, H.B. Verbruggeny, and H. Hellendoornzy. Promising fuzzy modeling and control methodologies for industrial applications. *ESIT'99, AB-02, Greece*, 1999. [cytowanie na str. 44, 53]
- [9] R. Balan and V. Maties. Nonlinear control using on line simulation and rule based control. *Proceedings of the IEEE International Conference on Mechatronics and Automation*,, pages 1031 – 1036, 2006. [cytowanie na str. 44]
- [10] R. Balan, V. Maties, O. Hancu, S. Stan, and L Ciprian. Nonlinear control using a model based predictive control algorithm. *International Symposium on Computational Intelligence in Robotics and Automation*, pages 510 – 515, 2007. [cytowanie na str. 44]

- [11] M.S. Bazaraa, Sherali H.D., and Shetty C.M. *Nonlinear programming. Theory and algorithms*. Wiley, 2006. [cytowanie na str. 37]
- [12] R. Bellman. *Adaptacyjne procesy sterowania*. PWN, 1965. [cytowanie na str. 47]
- [13] T. Bogdanik. *Matematyczna optymalizacja dawkowania leków*. Pol. Arch. Med. Wewn., 1971. [cytowanie na str. 2]
- [14] V.S. Borkar and S.P. Meyn. The ode method for convergence of stochastic approximation and reinforcement learning. *Journal of Control Optimization*, 38(2):447 – 469, 2000. [cytowanie na str. 60]
- [15] H. Brand and C. Wong. Application of knowledge based systems technology to triple quadrupole mass spectrometry. *AAAI: 5th national conference on artificial intelligence*, pages 812 – 819, 1986. [cytowanie na str. 45]
- [16] E. H. Bristol. Pattern recognition: An alternative to parameter identification in adaptive control. *Automatica*, pages 197 – 202, 1977. [cytowanie na str. 44]
- [17] K. Brzostowski. Some problems of neuromuscular system identification using two-stage principle. *Proceedings of the 16th International Conference on Systems Science ICSS*, pages 467 – 476, 2007. [cytowanie na str. 112]
- [18] K. Brzostowski and J. Drapała. Analysis of optimization methods in identification of human elbow neuromuscular model. *Information systems architecture and technology. Information models, concepts, tools and applications - 27th International Scientific School*, pages 59 – 67, 2006. [cytowanie na str. 112]
- [19] K. Brzostowski and J. Drapała. Analiza wrażliwości modelu układu neuromięśniowego. *Materiały Krakowskiej Konferencji Młodych Uczonych*, pages 77 – 82, 2007. [cytowanie na str. 112]
- [20] K. Brzostowski, J. Drapała, and J. Świątek. Model układu neuromięśniowego jako narzędzie diagnostyczne - analiza wrażliwości. *Biocybernetyka i inżynieria biomedyczna. XV Krajowa konferencja naukowa*, 2007. [cytowanie na str. 112]
- [21] K. Brzostowski and J. Świątek. Adaptive control algorithm with two-stage identification. *Proceedings of 18th International Conference on Systems Engineering ICSE*, pages 55 – 58, 2006. [cytowanie na str. 112]
- [22] K. Brzostowski and J. Świątek. Algorytm wyboru scenariusza z wykorzystaniem identyfikacji dwustopniowej. *VI Krajowa Konferencja Inżynieria Wiedzy i Systemy Ekspertowe*, pages 231 – 236, 2006. [cytowanie na str. 112]
- [23] K. Brzostowski and J. Świątek. On convergence an adaptive control algorithm based on pattern recognition. *Proceedings of the 16th International Conference on Systems Science ICSS*, pages 341 – 350, 2007. [cytowanie na str. 112]

- [24] K. Brzostowski and J. Świątek. On self-tuning knowledge-based controller using pattern recognition with application to non-linear biomedical object. *Information systems architecture and technology. Information models, concepts, tools and applications - 28th International Scientific School*, pages 175 – 182, 2007. [cytowanie na str. 112]
- [25] K. Brzostowski and J. Świątek. On the quality of expert's knowledge in an adaptive decision making system using classifiers. *Computer systems engineering. Theory and applications*, 2007. [cytowanie na str. 112]
- [26] K. Brzostowski and J. Świątek. A pattern recognition algorithm used in knowledge-based adaptive control system to select strategy. *Conference on Knowledge-Based and Intelligent Engineering Systems*, pages 247 – 254, 2007. [cytowanie na str. 112]
- [27] K. Brzostowski and J. Świątek. *Adaptacyjny algorytm wyboru scenariusza oparty na wiedzy eksperta*. Problemy Współczesnej Nauki, Sterowanie i Automatyzacja. EXIT, 2008. [cytowanie na str. 112]
- [28] K. Brzostowski and J. Świątek. Selecting scenario in adaptive system with neuro-fuzzy decision maker. *Proceedings of Nineteenth International Conference on Systems Engineering*, pages 195 – 200, 2008. [cytowanie na str. 112]
- [29] K. Brzostowski, J. Świątek, and J. Drapała. Application of two-stage adaptive decision making system based on takagi-sugeno model for scenario selection in rehabilitation process. *14th International Congress of Cybernetics and Systems of WOSC*, pages 253 – 260, 2008. [cytowanie na str. 112]
- [30] K. Brzostowski, J. Świątek, and J. Drapała. How to replace inexact expert's knowledge by precise diagnostic system - assessment of internal state of human elbow neuromuscular system. *Knowledge processing and reasoning for information society*, 2008. [cytowanie na str. 112]
- [31] K. Brzostowski, J. Świątek, J. Drapała, and A. Moskała. Difference equations and neural networks as a diagnostic tools for human elbow neuromuscular system. *Computer systems engineering. Theory and applications*, pages 128 – 137, 2007. [cytowanie na str. 112]
- [32] J. Bubnicki, Z. ans Świątek. On the parameter estimation in the identyfication of complex static system. *Bulletin de l'Academie Polonaise des Sciences. Serie des Sciences Techniques*, pages 35 – 44, 1981. [cytowanie na str. 13]
- [33] Z. Bubnicki. *Identyfikacja obiektów sterowania*. Państwowe Wydawnictwo Naukowe, 1974. [cytowanie na str. 65, 113]
- [34] Z. Bubnicki. On the multistage identification. *System Science*, 3(2):207 – 210, 1977. [cytowanie na str. 13]

- [35] Z. Bubnicki. Problems of the complex systems identyfication. *Proceedings of International Conference on Systems Engineering*, pages 5 – 17, 1980. [cytowanie na str. 13]
- [36] Z. Bubnicki. Knowledge-based decision making in expert systems. *Sixth International Conference on Systems Engineering*, pages 629 – 635, 1988. [cytowanie na str. 43]
- [37] Z. Bubnicki. Problems of control and identification expert systems. *Kompleksnaja awtomatizacija promyslennosti. III pol'sko-sovetskaja naucno-techniceskaja konferencija*, pages 27 – 36, 1988. [cytowanie na str. 43]
- [38] Z. Bubnicki. Problems of knowledge - based control systems. *7th International Conference on Systems Engineering*, pages 501 – 508, 1990. [cytowanie na str. 43]
- [39] Z. Bubnicki. Knowledge updating in a class of knowledge-based learning control systems. *Systems Science*, 23(4):19 – 36, 1997. [cytowanie na str. 43]
- [40] Z. Bubnicki. Learning process in a class of knowledge-based systems. *Kybernets*, 29(7/8):1016 – 1028, 2000. [cytowanie na str. 43, 70]
- [41] Z. Bubnicki. Uncertain variables and their application to decision making problems. *IEEE Transaction on Systems, Man, and Cybernetics*, 31(6):587 – 596, 2001. [cytowanie na str. 43]
- [42] Z. Bubnicki. *Teoria i algorytmy sterowania*. PWN, 2002. [cytowanie na str. 1, 7, 8, 9, 27, 43, 44, 65, 70]
- [43] T.S. Buchanan, D.G. Lloyd, K. Manal, and T.F. Besieer. Neuromusculoskeletal modeling: Estimation of muscle forces and joint moments and movements from measurements of neural command. *Journal of Applied Biomechanics*, pages 367 – 395, 2004. [cytowanie na str. 30, 31, 32]
- [44] Y.Y. Cao and P.M. Frank. Analysis and synthesis of nonlinear time-delay systems via fuzzycontrol approach. *IEEE Transactions on Fuzzy Systems*, 8(2):200 – 211, 2000. [cytowanie na str. 54]
- [45] Cz. Cempel and M. Tabaszewski. Zastosowanie teorii szarych systemów do modelowania i prognozowania w diagnostyce maszyn. *Diagnostyka*, pages 11 – 18, 2007. [cytowanie na str. 113]
- [46] H.F. Chen. *Stochastic Approximation and Its Application*. Springer, 2002. [cytowanie na str. 60]
- [47] J. Cichosz. Komputerowe algorytmy złożonej identyfikacji rekurencyjnej. *Raporty Wydz. Zakł Syst. Sieci Komput. PWroc.*, 2001. [cytowanie na str. 13]
- [48] J. Cichosz. On two-stage recursive identification. *Proceedings of the 10th Conference on System-Modelling-Control*, pages 129 – 134, 2001. [cytowanie na str. 13]

- [49] P. Cichosz. *Systemy uczące się*. WNT, 2000. [cytowanie na str. 52]
- [50] W.J. Cleancey. Viewing knowledge bases as qualitative models. *IEEE Intelligent Systems*, pages 9 – 15, 1989. [cytowanie na str. 45]
- [51] D.M. Corcos, G.L. Gottlieb, M.L. Latash, G.L. Almeida, and G.C. Agarwal. Electromechanical delay: An experimental artifact. *Journal of Electromyography and Kinesiology*, 2(2):59 – 68, 1992. [cytowanie na str. 32]
- [52] J.Z. Cypkin. Learning - what is it? *IEEE Transaction on Automatic Control*, AC-13(6):608 – 612, 1968. [cytowanie na str. 43, 65]
- [53] J.Z. Cypkin. *Podstawy teorii układów uczących się*. WNT, 1973. [cytowanie na str. 17, 28, 43, 69, 70]
- [54] B. Delyon. General results on the convergence of stochastic algorithms. *IEEE Transactions on Automatic Control*, pages 1245 – 1255, 1996. [cytowanie na str. 60]
- [55] J. Ding, C.K.L. Samuele, T.E. Johnston, A.S. Wexler, W.B. Scott, and S.A. Binder-Macleod. Mathematical model that predicts isometric muscle forces for individuals with spinal cord injuries. *Muscle and Nerve*, pages 702 – 712, 2005. [cytowanie na str. 23]
- [56] J. Ding, A.S. Wexler, and S.A. Binder-Macleod. A predictive model of fatigue in human skeletal muscles. *Journal of Applied Physiology*, page 1322 – 1332, 2000. [cytowanie na str. 23, 90, 91]
- [57] D. Driankov, H. Hellendoorn, and M. Reinfrank. *Wprowadzenie do sterowania rozmytego*. WNT, 1996. [cytowanie na str. 54]
- [58] R.O. Duda, P.E. Hart, and D.G. Stork. *Pattern Classification*. Wiley-Interscience, 2000. [cytowanie na str. 28]
- [59] G.A. Dumont and M. Huzmezan. Concepts, methods and techniques in adaptive control. *Proceedings of the American Control Conference*, 2:1137 – 1150, 2002. [cytowanie na str. 66]
- [60] Walter E. and Pronzato L. *Identification of parametric models*. Springer, 1997. [cytowanie na str. 37]
- [61] J. Espinosa, J. Vandewalle, and V. Wertz. *Fuzzy Logic, Identification and Predictive Control (Advances in Industrial Control)*. Springer, 2004. [cytowanie na str. 104]
- [62] W. Findeisen. *Wielopoziomowe układy sterowania*. PWN, 1974. [cytowanie na str. 16, 26, 44, 64, 65]
- [63] W. Findeisen. *Struktury Sterowania dla złożonych systemów*. WPW, 1997. [cytowanie na str. 16, 65]

- [64] G.K. Fitzgerald, M.J. Axe, and L. Snyder-Mackler. A decision-making scheme for returning patients to high-level activity with nonoperative treatment after anterior cruciate ligament rupture. *Knee Surgery, Sports Traumatology, Arthroscopy*, 8(2):76 – 82, 2000. [cytowanie na str. 2]
- [65] J.P. Forestier and P. Varaiya. Multilayer control of large markov chains. *IEEE Transaction Automatic Control*, AC-23(2):298 – 304, 1978. [cytowanie na str. 44, 46, 64]
- [66] L. Frangu, S. Carman, and E. Ceanga. A pattern recognition controller applied to the bioprocess control. *Proceedings of The 13-th International Conference on Control Systems and Computer Science CSCS13*, pages 187 – 191, 2001. [cytowanie na str. 45]
- [67] L. Frangu, E. Ceanga, S. Caraman, and Y. Boutalis. A pattern recognition approach to intelligent behaviours: Switching the startegies. *IEEE International Symposium Intelligent Systems*, pages 369 – 372, 2002. [cytowanie na str. 44]
- [68] Law L.A. Frey and R.K. Shields. Mathematical models use varying parameter strategies to represent paralyzed muscle force properties: a sensitivity analysis. *Journal of Neuroengineering Rehabilitation*, 2005. [cytowanie na str. 23, 91, 93]
- [69] Law L.A. Frey and R.K. Shields. Predicting human chronically paralyzed muscle force: a comparison of three mathematical models. *Journal of Applied Physiology*, pages 1027 – 1036, 2006. [cytowanie na str. 6]
- [70] M. Gieracha. Rekurencyjne algorytmy identyfikacji dwustopniowej obiektów dynamicznych (rozprawa doktorska). *Raporty Inst. Inform. Tech. PWroc*, 2005. [cytowanie na str. 14]
- [71] M. Gieracha and J. Świątek. Recursive two-stage estimation algorithms-simulation study. *Fourteenth International Conference on Systems Engineering. Proceedings, Coventry*, pages 552 – 556, 2000. [cytowanie na str. 14]
- [72] M. Gieracha and J. Świątek. Estimation error as a measure for on-line two-stage experiment design. *Proceedings of the 14th International Conference on Systems Science, Wrocław*, pages 227 – 233, 2001. [cytowanie na str. 14]
- [73] B.J. Glass and C. Wong. A knowledge-based approach to identification and adaptation indynamical systems control. *Proceedings of the 27th IEEE Conference on Decision and Control*, 1:881 – 886, 1988. [cytowanie na str. 45]
- [74] H. Górecki. *Optymalizacja i sterowanie systemów dynamicznych*. AGH, 2006. [cytowanie na str. 28]

- [75] J. Gutenbaum. *Modelowanie matematyczne systemów*. EXIT, 2003. [cytowanie na str. 37]
- [76] T.K. Hamrita. Pattern recognition for modeling and online diagnosis of bio-process. *IEEE Transaction on Industry Application*, 36(5):1295 – 1299, 2000. [cytowanie na str. 45]
- [77] Z. Hasiewicz. *Identyfikacja sterowanych systemów o złożonej strukturze*. Wydawnictwo Politechniki Wrocławskiej, 1993. [cytowanie na str. 15]
- [78] E. Ikonen and K. Najim. *Advanced Process Identification and Control*. CRC, 2001. [cytowanie na str. 37, 104]
- [79] E. Ikonen, K. Najim, and A.K. Daoud. *Stochastic Processes*. Butterworth-Heinemann, 2004. [cytowanie na str. 60]
- [80] J. Jakubowski and R. Sztencel. *Wstęp do teorii prawdopodobieństwa*. SCRIPT, 2000. [cytowanie na str. 57, 58, 59]
- [81] J.R. James and G.J. Suski. A survey of some implementations of knowledge-based systems for real-time control. *Proceedings of the 27th IEEE Conference on Decision and Control*, pages 580 – 585, 1988. [cytowanie na str. 45]
- [82] A. Jaskólski. *Podstawy fizjologii wysiłku fizycznego z zarysem fizjologii człowieka*. Wydawnictwo AWF we Wrocławiu, 2002. [cytowanie na str. 84]
- [83] T.A. Johansen. Fuzzy model based control: stability, robustness, and performance issues. *IEEE Transactions on Fuzzy Systems*, 2(3):221 – 234, 1994. [cytowanie na str. 44, 54]
- [84] J. Kacprzyk. *Wieloetapowe sterowanie rozmyte*. WNT, 2001. [cytowanie na str. 46, 47, 49, 50]
- [85] T. Kaczorek. *Teoria sterowania t. 1 i 2*. PWN, 1981. [cytowanie na str. 28]
- [86] T. Kaczorek. *Teoria sterowania i systemów*. PWN, 1999. [cytowanie na str. 28]
- [87] D.G. Kamper, B. D. Schmit, and W. Z. Rymer. Effect of muscle biomechanics on the quantification of spasticity. *Annals of Biomedical Engineering*, 12(29):1122 – 1134, 2001. [cytowanie na str. 2]
- [88] D. Kannan. *Introduction to Stochastic Processes*. Elsevier, 1979. [cytowanie na str. 60]
- [89] J. Kiwerski. *Urazy kręgosłupa odcinka szyjnego i ich następstwa*. PZWL, 1993. [cytowanie na str. 5, 6, 23]
- [90] K.B. Konstantinov and T. Yoshida. A knowledge-based pattern recognition approach for real-time diagnosis and control of structure plants. *IEEE Transaction on Systems, Man, and Cybernetics*, 21(4):908 – 914, 1991. [cytowanie na str. 45]

- [91] P. Korba, R. Babuska, H.B. Verbruggen, and P.M. Frank. Fuzzy gain scheduling: controller and observer design based on lyapunov method and convex optimization. *IEEE Transactions on Fuzzy Systems*, 11(3):285 – 298, 2003. [cytowanie na str. 54]
- [92] J. Korbicz, J.M. Kościelny, Z. Kowalczyk, and Cholewy W. *Diagnostyka procesów: Modele, metody sztucznej inteligencji i zastosowania*. WNT, 2002. [cytowanie na str. 27]
- [93] J. Koronacki. *Aproksymacja stochastyczna. Metody optymalizacji w warunkach losowych*. WNT, 1989. [cytowanie na str. 60, 61]
- [94] J. Koronacki and J. Ówik. *Statystyczne systemy uczące się*. WNT, 2005. [cytowanie na str. 28]
- [95] A.J. Krijgsman, H.M.T. Broeders, H.B. Verbruggen, and P.M. Bruijn. Knowledge-based control. *Proceedings of the 27th IEEE Conference on Decision and Control*, 1:570 – 574, 1988. [cytowanie na str. 44]
- [96] P. Kulczycki, O. Hryniewicz, and J. Kacprzyk. *Techniki informacyjne w badaniach systemowych*. WNT, 2007. [cytowanie na str. 47, 51]
- [97] M. Kurzyński. *Rozpoznawanie obiektów. Metody statystyczna*. Oficyna Wydawnicza Politechniki Wrocławskiej, 1997. [cytowanie na str. 17, 67, 68]
- [98] H. Kushner. *Introduction to Stochastic Control*. Holt, Rinehart and Winston, 1971. [cytowanie na str. 57, 60, 61]
- [99] H. Kushner and G. Yin. *Stochastic Approximation and Recursive Algorithms and Applications*. Springer, 2003. [cytowanie na str. 60, 61]
- [100] C.H. Lee and C.C. Teng. Identification and control of dynamic systems using recurrent fuzzyneural networks. *IEEE Transactions on Fuzzy Systems*, 8(4):349 – 366, 2000. [cytowanie na str. 54]
- [101] O. Levin, J. Mizrahi, M. Gornish, and E. Isakov. Muscle strength and geometrical changes in a paralysed muscle following fes. *Hong Kong Physiotherapy Journal*, pages 3 – 11, 2000. [cytowanie na str. 23]
- [102] K.Y. Lian, H.W. Tu, and J.J. Liou. Fuzzy model and control for hybrid systems using averaging techniques. *SICE-ICASE International Joint Conference*, pages 628 – 633, 2006. [cytowanie na str. 54]
- [103] J.Z. Liu, R.W. Brown, and G.H. Yue. A dynamical model of muscle activation, fatigue and recovery. *Biophysical Journal*, 82:2344 – 2359, 2002. [cytowanie na str. 91]
- [104] Z.Q. Liu and F. Yan. Fuzzy neural network in case-based diagnostic systems. *IEEE Transaction on Fuzzy Systems*, 5(2):209 – 222, 1997. [cytowanie na str. 43]

- [105] L. Ljung. Analysis of recursive stochastic algorithms. *IEEE Transactions on Automatic Control*, pages 551 – 574, 1977. [cytowanie na str. 59]
- [106] L. Ljung, B. Wahlber, and H. Hjalmarsson. Model quality: the roles of prior knowledge and data information. *Proceeding of the 30th Conference on Decision and Control*, pages 273 – 278, 1991. [cytowanie na str. 43]
- [107] D.G. Lloyd and T.F. Besier. An emg-driven musculoskeletal model for estimation of the human knee joint moments across varied tasks. *Journal of Biomechanics*, pages 765 – 776, 2003. [cytowanie na str. 30]
- [108] D.G. Lloyd and T.S. Buchanan. A model of load sharing between muscles and soft tissues at the human knee during static tasks. *Journal of Biomechanical Engineering*, pages 367 – 376, 1996. [cytowanie na str. 30]
- [109] Tokarski M. Koncepcja systemu optymalnego wyboru leku oparta na teorii zbiorów rozmytych. *Probl. Techn. Med.*, pages 109 – 118, 1982. [cytowanie na str. 2]
- [110] K. Mańczak and Z. Nahorski. *Komputerowa identyfikacja obiektów dynamicznych*. PWN, 1983. [cytowanie na str. 37]
- [111] H. Makssoud, D. Guiraud, and P. Poignet. Mathematical muscle model for functional electrical stimulation control strategies. *International Conference on Robotics and Automation*, pages 1282 – 1287. [cytowanie na str. 6]
- [112] H.E. Makssoud, D. Guiraud, and P. Poignet. Mathematical muscle model for functional electrical stimulation. *Proceeding of the IEEE International Conference on Robotics and Automation*, pages 1282 – 1287, 2004. [cytowanie na str. 23]
- [113] K. Manal and T. S. Buchanan. Modeling the non-linear relationship between emg and muscle activation. *Journal of Biomechanics*, pages 1197 – 1202, 2003. [cytowanie na str. 30]
- [114] K. Manal and T. S. Buchanan. A one-parameter neural activation to muscle to muscle activation model: estimating isometric joint moments from electromyograms. *Journal of Biomechanics*, pages 1197 – 1202, 2003. [cytowanie na str. 30, 32, 33]
- [115] K. Manal, R. V. Gonzales, D. G. Lloyd, and T.S. Buchanan. A real-time emg-driven virtual arm. *Computational Biology and Medicine*, pages 25 – 36, 2002. [cytowanie na str. 30, 31, 79]
- [116] M. Metivier and P. Priouret. Applications of a kushner and clark lemma to general classes of stochastic algorithms. *IEEE Transactions on Information Theory*, pages 140 – 151, 1984. [cytowanie na str. 60]
- [117] S.P. Meyn and R.L. Tweedie. *Markov Chains and Stochastic Stability*. Springer, 1993. [cytowanie na str. 57]

- [118] S. Molloy, T. van den Boom, F. Cuesta, A. Ollero, and Babuska R. Robust stability constraints for fuzzy model predictive control. *IEEE Transactions on Fuzzy Systems*, 10(1):50 – 64, 2000. [cytowanie na str. 54]
- [119] A. Morecki and J. Knapczyk. *Teoria mechanizmów i manipulatorów*. WNT, 2001. [cytowanie na str. 29, 75, 76, 77, 78]
- [120] O. Nelles. *Nonlinear System Identification - From Classical Approaches to Neural Networks and Fuzzy Models*. Springer-Verlag, 2001. [cytowanie na str. 37]
- [121] A. Niederlinski, J. Moscinski, and Z. Ogonowski. *Regulacja adaptacyjna*. PWN, 1995. [cytowanie na str. 65]
- [122] A. Niederliński. *Systemy komputerowe automatyki przemysłowej t.1 - Sprzęt i oprogramowanie*. WNT, 1985. [cytowanie na str. 65]
- [123] A. Niederliński. *Systemy komputerowe automatyki przemysłowej t.2 - Zastosowania*. WNT, 1985. [cytowanie na str. 65]
- [124] T.D. Noakes. Physiological models to understand exercise fatigue and the adaptations that predict or enhance athletic performance. *Scandinavian Journal of Medicine and Science in Sports*, pages 123 – 145, 2000. [cytowanie na str. 91]
- [125] S. Osowski. *Sieci neuronowe w ujęciu algorytmicznym*. WNT, 1996. [cytowanie na str. 52, 80]
- [126] A.S. Poznyak, K. Najim, and E. Gomez Ramirez. *Self-Learning Control of Finite Markov Chains*. Marcel Dekker, 2000. [cytowanie na str. 52]
- [127] R. Qi and M. A. Brdys. Adaptive fuzzy modelling and control for discrete-time nonlinear uncertain systems. *Proceedings of the American Control Conference*, 2:1108 – 1113, 2005. [cytowanie na str. 54]
- [128] R.T. Raikova and H. Ts. Aladjov. Experimental and modeling investigation of learning fast elbow flexion in the horizontal plane. *Journal of Biomechanics*, pages 2070 – 2077, 2005. [cytowanie na str. 30]
- [129] M. Ramoni, M. Stefanelli, L. Magnani, and G. Barosi. An epistemological framework for medical knowledge-based systems. *IEEE Transactions on Systems, Man and Cybernetics*, 22(6):1361 – 1375, 1992. [cytowanie na str. 45]
- [130] R.C. Raymond. Use of the time-sharing computer in business planning and budgeting. *Management Science*, 12(8):363 – 381, 1966. [cytowanie na str. 1]
- [131] D. Rutkowska, M. Piliński, and L. Rutkowski. *Sieci neuronowe, algorytmy genetyczne i systemy rozmyte*. PWN, 1999. [cytowanie na str. 80]

- [132] L. Rutkowski. *Metody i techniki sztucznej inteligencji*. PWN, 2006. [cytowanie na str. 54]
- [133] N. Sadati and D. Marvast. Stochastic control of two-level nonlinear large scale systems: part 1 - interaction prediction principle. *IEEE Conferenc on Systems, Man, and Cybernetics*, pages 3850 – 3855, 2006. [cytowanie na str. 16]
- [134] N. Sadati and D. Marvast. Stochastic control of two-level nonlinear large scale systems: part 2 - interaction balance principle. *IEEE Conferenc on Systems, Man, and Cybernetics*, pages 3856 – 3861, 2006. [cytowanie na str. 16]
- [135] G. N. Saridis. Application of pattern recognition methods to control systems. *IEEE Transactions on Automatic Control*, pages 638 – 645, 1981. [cytowanie na str. 45]
- [136] A.A. Seif. On the adaptive pattern recognition control. *Proceedings of Computer Systems and Software Engineering*, pages 706 – 709, 1992. [cytowanie na str. 45]
- [137] X.A. Shi, X.S. Zhou, J.H. Gu, and Y. Lin. Pattern recognition based adaptive real-time scheduling. *Proceeding os the second Internationl Confeerence on Machine Learning and Cybernetics*, pages 3160 – 3166, 2003. [cytowanie na str. 44]
- [138] L. Sifeng and L. Yi. Introduction to grey system theory. *IEEE International Conference on System, Man and Cybernetics*, pages 2403 – 2408, 2004. [cytowanie na str. 113]
- [139] J. Łęski. *Systemy neuronowo-rozmyte*. WNT, 2008. [cytowanie na str. 43, 54]
- [140] I. Skrjanc and D. Matko. Predictive functional control based on fuzzy model for heat-exchanger pilot plant. *IEEE Transactions on Fuzzy Systems*, 8(6):705 – 712, 2000. [cytowanie na str. 54]
- [141] D.J. Sobajic, Y.H. Pao, and D.T. Lee. Robust control of nonlinear systems using pattern recognition. *Conference Proceedings of IEEE International Conference on Systems, Man and Cybernetics*, pages 315 – 320, 1989. [cytowanie na str. 45]
- [142] T. Soderstrom and P. Stoica. *Identyfikacja systemów*. PWN, 1997. [cytowanie na str. 37]
- [143] M. Song, G. Gu, and R. Zhang. Behavior control of multi-robot using the prior-knowledge based reinforcement learning. *WCICA 2004. Fifth World Congress on Intelligent Control and Automation*, 6:5027 – 5030, 2004. [cytowanie na str. 45]
- [144] J.T. Spooner and K.M. Passino. Stable adaptive control using fuzzy systems and neural networks. *1996*, 4(3):339 – 359, *IEEE Transactions on Fuzzy Systems*. [cytowanie na str. 54]

- [145] V.G. Sragovich. *Mathematical theory of adaptive control*. World Scientific, 2006. [cytowanie na str. 57]
- [146] M. Stopczyk. *Elektrodiagnostyka medyczna*. PZWL, 1984. [cytowanie na str. 30, 79]
- [147] D. Stroock. *An introduction to stochastic markov processes*. Springer, 2005. [cytowanie na str. 61]
- [148] J. Świątek. Model matematyczny i identyfikacja procesów hemodynamicznych w układzie krążenia (rozprawa doktorska). *Raport z serii PREPRINTY*, 84, 1979. [cytowanie na str. 34, 35, 112]
- [149] P. Tatjewski. *Sterowanie zaawansowane obiektów przemysłowych. Struktury i algorytmy*. EXIT, 2002. [cytowanie na str. 104]
- [150] S. Theodoridis and K. Koutroumbas. *Pattern Recognition*. Academic Press, 2006. [cytowanie na str. 28]
- [151] A.H. Tilton. Approach to the rehabilitation of aspasticity and neuromuscular disorders in children. *Neurologic Clinic*, pages 853 – 881, 2003. [cytowanie na str. 5]
- [152] W. Traczyk and Trzebski A. *Fizjologia człowieka z elementami fizjologii stosowanej i klinicznej*. PZWL, 2007. [cytowanie na str. 91, 93]
- [153] S. Trier, T. Vrabec, and J. Weisgarber. Using functional electrical stimulation to restore movement to individuals with neuromuscular disabilities. *The MathWorks News and Notes*, pages 24 – 29. [cytowanie na str. 6]
- [154] E. Turban. The use of mathematical models in plant maintenance decision making. *Management Science*, 13(6):342 – 359, 1967. [cytowanie na str. 1]
- [155] G.L. Urban. A tool for new products decision makers. *Industrial Management Review*, 8(2):43 – 54, 1967. [cytowanie na str. 1]
- [156] E. Waniewski and J. Doroszewski. *Informatyka medyczna t.6*. WKŁ, 1990. [cytowanie na str. 2, 25, 44]
- [157] A.D. Wentzell. *Wykłady z teorii procesów stochastycznych*. PWN, 1980. [cytowanie na str. 57]
- [158] D.T. Westwick and R.E. Kearney. *Identification of Nonlinear Physiological Systems*. Wiley-IEEE Press, 2003. [cytowanie na str. 37]
- [159] A. Wierzbicki. *Modele i wrażliwość układów sterowania*. WNT, 1977. [cytowanie na str. 34, 35]
- [160] J. Świątek. *Identyfikacja dwustopniowa i jej zastosowania techniczne i biomedyczne*. Wydawnictwo Politechniki Wrocławskiej, 1987. [cytowanie na str. 14, 15, 16, 17, 26, 27, 39]

- [161] J. Świątek. Problems of complex systems identification for adaptive control. *Proceedings of the Ninth International Conference on Systems Engineering*, pages 280 – 284, 1993. [cytowanie na str. 14]
- [162] J. Świątek. On-line two-stage estimation algorithms for dynamic systems. *Tenth International Conference on Systems Engineering*, 2:1206 – 1212, 1994. [cytowanie na str. 14]
- [163] J. Świątek. Self-tuning control via pattern recognition for discrete type systems. *Proceedings of the Eleventh International Conference on Systems Engineering*, pages 134 – 139, 1996. [cytowanie na str. 45]
- [164] J. Świątek. Two-stage estimation algorithms for adaptive control. *Twelfth International Conference on Systems Engineering. Proceedings*, 2:670 – 672, 1997. [cytowanie na str. 14]
- [165] J. Świątek. Rekurencyjne algorytmy identyfikacji dwustopniowej. *XII Krajowa Konferencja Automatyki*, pages 261 – 264, 1999. [cytowanie na str. 13, 14]
- [166] J. Świątek. Parameter estimation of systems described by the relation by maximum likelihood method. *Lecture Notes in Artificial Intelligence*, pages 1217 – 1222, 2006. [cytowanie na str. 113]
- [167] J. Świątek. *Wybrane zagadnienia identyfikacji statycznych systemów złożonych*. Wydawnictwo Politechniki Wrocławskiej, 2009. [cytowanie na str. 11]
- [168] J. Świątek and A. M. Abdel Ghany. Design of controller for two stage dynamic system. *Proceedings of the Second IASTED International Conference: Computer applications in industry*, pages 68 – 71, 1992. [cytowanie na str. 14]
- [169] J. Świątek and A. M. Abdel Ghany. Identification of the two-stage dynamic system using instrumental variable method. *Proceedings of the 13th International Conference on Systems Science*, 1:243 – 252, 1998. [cytowanie na str. 14]
- [170] W. Wojnicz and E. Wittbrodt. Modelowanie i symulacja zachowania mięśnia szkieletowego o różnych własnościach dynamicznych. *Zeszyty naukowe Katedry Mechaniki Stosowanej*, 2004. [cytowanie na str. 29]
- [171] W. Wojnicz and E. Wittbrodt. Modelowanie zachowania zespołu mięśni szkieletowych w układzie ramię - przedramię. *Zeszyty naukowe Katedry Mechaniki Stosowanej*, pages 152 – 159, 2005. [cytowanie na str. 29, 30]
- [172] M. Woszczak. Postępowanie rehabilitacyjne w stwardnieniu rozsianym. *Via Medica*, pages 130 – 133, 2005. [cytowanie na str. 6]

- [173] M.S. Yang and C.H. Chen. On the edited fuzzy k-nearest neighbor rule. *IEEE Transactions on Systems, Man, and Cybernetics, Part B*, 28(3):461 – 466, 1998. [cytowanie na str. -]
- [174] B.S. Zhang and J.R. Leigh. Learning control based on pattern recognition applied to vehicle cruise control sytems. *Proceeding of the American Control Conference*, 3101 - 3105 1995. [cytowanie na str. 45]

Wykaz ważniejszych oznaczeń

Skrót	Opis
$\Phi_1\left(y(k_1 - 1), u_1(k_1); \mathbf{a}_1(k_2)\right)$	model obiektu na 1. stopniu
$\Phi_2\left(\mathbf{a}_1(k_2 - 1), \pi(k_2); \mathbf{a}_2(k_2)\right)$	model obiektu na 2. stopniu
$u_1(k_1)$	wejście obiektu na 1. stopniu
$y(k_1)$	wyjście obiektu na 1. stopniu
$\mathbf{a}_1(k_2)$	wektor parametrów modelu na 1. stopniu
$\mathbf{a}_2(k_2)$	wektor parametrów modelu na 2. stopniu
$\mathcal{U}_1 \subseteq \mathcal{R}^{S_1}$	przestrzeń wejść obiektu na pierwszym stopniu, podzbiór S_1 -wymiarowej przestrzeni liczb rzeczywistych
$\mathcal{A}_1 \subseteq \mathcal{R}^{R_1}$	przestrzeń parametrów obiektu na pierwszym stopniu, podzbiór R_1 -wymiarowej przestrzeni liczb rzeczywistych
$\mathcal{A}_2 \subseteq \mathcal{R}^{R_2}$	przestrzeń parametrów obiektu na drugim stopniu, podzbiór R_2 -wymiarowej przestrzeni liczb rzeczywistych
$\mathcal{Y} \subseteq \mathcal{R}^L$	przestrzeń wyjść obiektu na pierwszym stopniu, podzbiór L -wymiarowej przestrzeni liczb rzeczywistych
π	scenariusz decyzyjny
\aleph	zbiór scenariuszy decyzyjnych π
U_2	zbiór instrukcji wykorzystanych do budowy scenariuszy decyzyjnych $\pi \in \aleph$
k_1	numer taktu na pierwszym stopniu
k_2	numer taktu na drugim stopniu
$U_{1N_1, k_2} = \{u_{1k_2}(k_1)\}_{k_1=1}^{N_1}$	zbiór wyników pomiarów wejść dla obiektu na pierwszym stopniu

Skrót	Opis
$Y_{N_1, k_2} = \{y_{k_2}(k_1)\}_{k_1=1}^{N_1}$	zbiór wyników pomiarów wyjść dla obiektu na pierwszym stopniu
N_1	długość serii pomiarowej na pierwszym stopniu
$Q_1(\mathbf{a}_{1N_1}(k_2), \pi(k_2))$	kryterium jakości identyfikacji na 1. stopniu
$\hat{\mathbf{a}}_1(k_2)$	estymowana wartość parametru $\mathbf{a}_1(k_2)$ na 1. stopniu w chwili k_2
$\Psi_{1N_1}(U_{1N_1, k_2}, Y_{N_1, k_2})$	algorytm identyfikacji dla modelu na 1. stopniu
$\mathcal{S}(k_1, \mathbf{a}_1(k_1))$	funkcja wrażliwości
$\Delta \mathbf{a}_1(k_1)$	przyrost wektora wartości parametrów
$\Pi_{N_2} = \{\pi(k_2)\}_{k_2=1}^{N_2}$	zbiór wyników pomiarów wejść dla obiektu na drugim stopniu
$\hat{\mathbf{A}}_{1N_1, N_2} = \{\hat{\mathbf{a}}_{1n_1}(k_2)\}_{k_2=1}^{N_2}$	zbiór wyników estymacji wektora parametrów \mathbf{a}_1 modelu na pierwszym stopniu dla N_2 taktów identyfikacyjnych na drugim stopniu
N_2	długość serii pomiarowej na drugim stopniu
$Q_2(\mathbf{a}_2(k_2))$	kryterium jakości identyfikacji na 2. stopniu
$\hat{\mathbf{a}}_2(k_2)$	estymowana wartość parametru $\mathbf{a}_2(k_2)$ na 2. stopniu w chwili k_2
$\Psi_{2N_2}(\Pi_{N_2}, \hat{\mathbf{A}}_{1N_1, N_2})$	algorytm identyfikacji dla modelu na 2. stopniu
R_m	liczba reguł dla systemu <i>Takagi-Sugeno</i> wykorzystanego jako model obiektu na drugim stopniu
$\vartheta^{(r_m)}\left(\pi(k_2); m^{(r_m)}, \sigma^{(r_m)}\right)$	gaussowska funkcja przynależności dla systemu <i>Takagi-Sugeno</i> wykorzystanego jako model obiektu na drugim stopniu
$S = \{s_1, s_2, \dots, s_F\}$	zbiór stanów stochastycznego układu sterującego
\mathbf{a}_1^*	pożądana wartość wektora parametrów modelu na pierwszym stopniu
$w(k_2)$	zakłócenia pomiarowe na 2. stopniu
$\mathcal{W} \subseteq \mathcal{R}^{R_1}$	przestrzeń zakłóceń, podzbiór R_1 -wymiarowej przestrzeni liczb rzeczywistych
$\hat{\xi}(k_2) = q^{pd}(\mathbf{a}_1^*, \hat{\mathbf{a}}_{1N_1}(k_2))$	różnica pomiędzy wartością aktualną wektora parametrów $\hat{\mathbf{a}}_{1N_1}(k_2)$ a pożądaną \mathbf{a}_1^*
$g_w(\hat{\xi}(k_1); w(k_1))$	funkcja opisując wpływ zakłóceń pomiarowych na 2. stopniu
$\tilde{\xi}(k_1)$	pomiar zmiennej $\hat{\xi}(k_1)$ z zakłóceniem tj. $\tilde{\xi}(k_1) = g_w(\hat{\xi}(k_1); w(k_1))$
K_2	z góry zadany czas zakończenia procesu podejmowania decyzji

Skrót	Opis
\underline{K}_2	niejawnie zadany czas zakończenia procesu podejmowania decyzji
\underline{K}_2	rozmyty czas zakończenia procesu podejmowania decyzji
$\psi^{pd}(\hat{\xi}(k_2))$	algorytm wyboru scenariusza z góry czasem zakończenia \underline{K}_2
$\psi^{pd}(\hat{\xi}(\underline{k}_2))$	algorytm wyboru scenariusza z niejawnie zadanim czasem zakończenia \underline{K}_2
$\psi^{pd}(\hat{\xi}(\underline{k}_2))$	algorytm wyboru scenariusza z rozmytym czasem zakończenia \underline{K}_2
$(\pi^*(1), \pi^*(2), \dots, \pi^*(K_2))$	poszukiwany, optymalny ciąg decyzji
$\psi_{PR}^{pd}(\tilde{\xi}(k_2), X^{K_{pd}}, \mathbf{b})$	algorytm wyboru scenariusza dla procesu podejmowania decyzji z wykorzystaniem procedur rozpoznawania obiektów
$Q^{pd}(\pi(k_2); \tilde{\xi}(k_2))$	kryterium jakości procesu podejmowania decyzji
$X^{K_{pd}}$	ciąg uczący dla zadania wyboru scenariusza
$(\tilde{\pi}^*(1), \tilde{\pi}^*(2), \dots, \tilde{\pi}^*(K_2))$	rozwiązanie, suboptymalny ciąg decyzji
B	zbiór możliwych wartości wektora parametrów dla przybliżonego algorytmu wyboru scenariusza
$(\mathbf{b}^*(1), \mathbf{b}^*(2), \dots, \mathbf{b}^*(M))$	$\psi_{PR}^{pd}(\cdot, \cdot, \cdot)$ poszukiwany, optymalny ciąg wartości wektora parametrów algorytmu wyboru scenariusza
$\psi^s(\hat{\mathbf{a}}_2(m))$	algorytm strojenia algorytmu wyboru scenariusza dla procesu podejmowania decyzji
$\psi_{PR}^{pd}(\hat{\xi}(k_2), X^{K_{pd}}, \psi_{PR}^s(\hat{\mathbf{a}}_2(m), X^{K_s}))$	algorytm wyboru scenariusza dla procesu podejmowania decyzji z wykorzystaniem procedur rozpoznawania obiektów ze strojonym parametrem
X^{K_s}	ciąg uczący dla zadania strojenia przybliżonego algorytmu wyboru scenariusza
$Q^s(\mathbf{b}(m); \hat{\mathbf{a}}_2(m))$	kryterium jakości procesu strojenia przybliżonego algorytmu wyboru scenariusza
$(\tilde{\mathbf{b}}^*(1), \tilde{\mathbf{b}}^*(2), \dots, \tilde{\mathbf{b}}^*(M))$	rozwiązanie suboptymalne zdania strojenia algorytmu wyboru scenariusza
R_{PR}	liczba reguł dla systemu <i>Takagi-Sugeno</i> wykorzystanego jako algorytm wyboru scenariusza
$\mathbf{w}^{(r_{PR})} = [w^{(1)} \quad w^{(2)} \quad \dots \quad w^{(R_1)}]^T$	wektor parametrów systemu <i>Takagi-Sugeno</i> wykorzystanego jako algorytm wyboru scenariusza

Skrót	Opis
$\vartheta^{(r_{PR})}(\tilde{\xi}(k_2); m^{(r_{PR})}, \sigma^{(r_{PR})})$	gaussowska funkcja przynależności dla systemu <i>Takagi–Sugeno</i> wykorzystanego jako algorytm wyboru scenariusza
P	macierz przejść <i>łańcucha Markowa</i>
$(\Omega, \mathcal{F}, \mathbb{P})$	przestrzeń probabilistyczna
$\mathcal{F}(k_2)$	filtracja
$\mu(0)$	rozkład początkowy
$V(k_2) = \frac{1}{2}(\hat{\xi}(k_2))^2$	funkcja Lapunowa

Spis rysunków

1.1	System z algorytmem wspomaganie podejmowania decyzji w procesie planowania rehabilitacji	4
1.2	System z modelem i algorytmem wspomaganie podejmowania decyzji w procesie planowania rehabilitacji	4
1.3	Adaptacyjny system z modelem i algorytmem wspomaganie podejmowania decyzji w procesie planowania rehabilitacji	5
1.4	Otwarty system z algorytmem wspomaganie podejmowania decyzji	7
1.5	Zamknięty system z algorytmem wspomaganie podejmowania decyzji	7
1.6	Adaptacyjne wspomaganie podejmowania decyzji w systemie zamkniętym	8
1.7	Adaptacyjne wspomaganie podejmowania decyzji w systemie zamkniętym z wiedzą eksperta	9
1.8	Obiekt identyfikacji z wektorem wejść \mathbf{u} oraz wyjść \mathbf{y}	10
1.9	Układ identyfikacji	11
1.10	Wybór optymalnego modelu	12
1.11	Dwustopniowy obiekt identyfikacji	13
1.12	System adaptacyjnego wspomaganie podejmowania decyzji z identyfikacją dwustopniową	16
1.13	Obiekt rozpoznawania z wejściowym wektorem cech \mathbf{x} oraz wyjściowym numerem klasy i	18
2.1	Cztery przykładowe scenariusze pobudzania mięśni impulsami elektrycznymi	24
2.2	Dwie przykładowe sekwencje impulsów pobudzających złożone z pięciu dostępnych scenariuszy	24

2.3	Adaptacyjny system wspomagania podejmowania decyzji z identyfikacją dwustopniową i z wykorzystaniem wiedzy eksperta	27
2.4	Schemat kolejnych etapów przetwarzania sygnałów EMG	31
2.5	Zależność pomiędzy pobudzeniem mięśnia przez motoneurony a jego odpowiedzią na to pobudzenie	32
2.6	Struktura zaproponowanego systemu $T-S$ (2.33)	42
2.7	Pomiar wielkości $\mathbf{x}(k)$ z zakłóceniem $\mathbf{z}(k)$	48
2.8	Schemat systemu wspomagania podejmowania decyzji oparty na banku modeli neuronowo-rozmytych	56
2.9	Idea adaptacji poprzez strojenie	65
3.1	Stanowisko do pomiaru momentów sił (Katedra Fizjoterapii w Medycynie Zachowawczej i Zabiegowej Akademii Wychowania Fizycznego we Wrocławiu)	74
3.2	Stanowisko do pomiaru momentów sił (Katedra Fizjoterapii w Medycynie Zachowawczej i Zabiegowej Akademii Wychowania Fizycznego we Wrocławiu)	75
3.3	Umieszczenie elektrody nad odpowiednim mięśniami przed dokonaniem pomiaru	76
3.4	Pomiar generowanego momentu siły w warunkach dynamicznych	77
3.5	Dane pomiarowe do zadania identyfikacji modelu dla próby <i>statycznej</i>	80
3.6	Kolejne etapy przetwarzania sygnału EMG	81
3.7	Efekt identyfikacji modelu podstawowego (2.8) dla danych z próby <i>statycznej</i>	82
3.8	Efekt identyfikacji modelu w postaci dwuwarstwowej sieci neuronowej dla danych z próby <i>statycznej</i>	83
3.9	Efekt identyfikacji modelu w postaci systemu <i>Takagi – Sugeno</i> dla danych z próby <i>statycznej</i>	84
3.10	Dane pomiarowe do zadania identyfikacji modelu dla próby <i>dynamicznej</i>	85
3.11	Efekt identyfikacji modelu podstawowego (2.8) dla danych z próby <i>dynamicznej</i>	86
3.12	Dane pomiarowe (moment siły) do zadania identyfikacji modelu dla próby <i>dynamicznej</i> – badanie wpływu czasu ćwiczeń	86
3.13	Dane pomiarowe (EMG) do zadania identyfikacji modelu dla próby <i>dynamicznej</i> – badanie wpływu czasu ćwiczeń	87

3.14	Wpływ czasu ćwiczeń na maksymalny moment siły generowany podczas długotrwałego ćwiczenia (zginanie). Znormalizowane wejście i wyjście	87
3.15	Wrażliwość zaproponowanego modelu na zmiany jego parametrów . .	88
3.16	Porównanie zależności std/m dla modelu podstawowego (2.8), dwuwarstwowej sieci neuronowej oraz systemu <i>Takagi–Sugeno</i>	88
4.1	Przykład reakcji obiektu 1. i 2. na pojedyncze pobudzenie wyznaczone na podstawie scenariusza: 1. (z lewej) i 2. (z prawej)	94
4.2	Przykład reakcji obiektu 1. i 2. na pojedyncze pobudzenie wyznaczone na podstawie scenariusza: 3. (z lewej) i 4. (z prawej)	94
4.3	Przykład reakcji obiektu 1. na sekwencję pobudzeń wyznaczonych na podstawie scenariusza: 1. (z lewej) i 2. (z prawej)	95
4.4	Przykład reakcji obiektu 1. na sekwencję pobudzeń wyznaczonych na podstawie scenariusza: 3. (z lewej) i 4. (z prawej)	95
4.5	Przykład reakcji obiektu 1. na sekwencję pobudzeń wyznaczonych na podstawie losowo wybranych scenariuszy od 1 do 5	96
4.6	Algorytm oparty o k - <i>NN</i> : pomiar bez zakłóceń (z lewej), pomiar z zakłóceniami (z prawej)	97
4.7	Algorytm oparty o system <i>Takagi–Sugeno</i> : pomiar bez zakłóceń (z lewej), pomiar z zakłóceniami (z prawej)	98
4.8	Algorytm oparty o sieć neuronową: pomiar bez zakłóceń (z lewej), pomiar z zakłóceniami (z prawej)	98
4.9	Algorytm oparty o k - <i>NN</i> : pomiar bez zakłóceń (z lewej), pomiar z zakłóceniami (z prawej)	99
4.10	Algorytm oparty o system <i>Takagi–Sugeno</i> : pomiar bez zakłóceń (z lewej), pomiar z zakłóceniami (z prawej)	100
4.11	Algorytm oparty o sieć neuronową: pomiar bez zakłóceń (z lewej), pomiar z zakłóceniami (z prawej)	100
4.12	Pomiar sygnału wejściowego (na dole, po lewej) i wyjściowego (na górze, po lewej) dla zadania identyfikacji na 2. stopniu oraz wynik identyfikacji dla modelu procesu na 2. stopniu (po prawej)	102
4.13	Strojony algorytm podejmowania decyzji oparty o system <i>Takagi–Sugeno</i> i procedurę <i>NM</i> : pomiar bez zakłóceń (z lewej), pomiar z zakłóceniami (z prawej)	103

4.14	Wpływ częstości strojenia na jakość procesu wspomaganie podejmowania decyzji dla strojonego algorytmu podejmowania decyzji oparte o system <i>Takagi-Sugeno</i> i procedurę <i>NM</i>	103
4.15	Adaptacyjny algorytm podejmowania decyzji oparty o system <i>Takagi-Sugeno</i> z aktualizacją wiedzy eksperta – wariant I: pomiar bez zakłóceń (z lewej), pomiar z zakłóceniami (z prawej)	105
4.16	Adaptacyjny algorytm podejmowania decyzji oparty o system <i>Takagi-Sugeno</i> z aktualizacją wiedzy eksperta – wariant II: pomiar bez zakłóceń (z lewej), pomiar z zakłóceniami (z prawej)	106
4.17	Wpływ kroku predykcji dla metody predykcyjnego wspomaganie podejmowania decyzji (horyzont = 1, 2, 3, 4, 5; pomiar bez zakłóceń)	106
4.18	Predykcyjne wspomaganie podejmowania decyzji oparte o metodę przeglądu zupełnego (pomiar bez zakłóceń): horyzont = 3 (z lewej), horyzont = 1 (z prawej)	107
4.19	Wpływ kroku predykcji dla metody predykcyjnego wspomaganie podejmowania decyzji (horyzont = 1, 2, 3, 4, 5; pomiar z zakłóceniami)	107
4.20	Predykcyjne wspomaganie podejmowania decyzji oparte o metodę przeglądu zupełnego (pomiar z zakłóceniami): horyzont = 3 (z lewej), horyzont = 1 (z prawej)	108
4.21	1 - Algorytm dokładny; 2 - Algorytm oparty o system <i>Takagi-Sugeno</i> ; 3 - Algorytm oparty o system <i>Takagi-Sugeno</i> z strojeniem; 4 - Algorytm oparty o system <i>Takagi-Sugeno</i> z aktualizacją wiedzy – wariant I; 5 - Algorytm oparty o system <i>Takagi-Sugeno</i> z aktualizacją wiedzy – wariant II. Wyniki dla przypadku bez zakłóceń (z lewej) oraz dla przypadku z zakłóceniami (z prawej)	108

Spis tabel

3.1	Wartości wektora wag \mathbf{w} sieci neuronowej dla ośmiu zdrowych osób biorących udział w eksperymencie	81
3.2	Wartości wektora parametrów systemu <i>Takagi – Sugeno</i> dla ośmiu zdrowych osób biorących udział w eksperymencie	82
3.3	Wartości wektora parametrów \mathbf{a}_1 dla ośmiu zdrowych osób biorących udział w eksperymencie	85

Skorowidz

- ćwiczenia rehabilitacyjne, 6
- adaptacyjnego podejmowania decyzji, algorytm, 8
- adaptacyjnego wspomaganie podejmowania decyzji, system, 8
- adaptator, 26, 27, 39, 64, 65
- algorytm adaptacji, 8
- algorytm identyfikacji, 37
- algorytm Newtona, 52
- algorytm podejmowania decyzji, 27, 39, 45, 54, 61, 64, 65, 67
- algorytm podejmowania decyzji, adaptacyjny, 22, 54
- algorytm rozpoznawania obiektów, 44, 52, 67
- algorytm uczenia z nadzorem, 52
- algorytm uczenia ze wzmocnieniem, 52
- algorytm wspomagający podejmowanie decyzji, 26
- algorytm wspomaganie podejmowania decyzji, 7, 27, 43, 45, 47
- algorytmem podejmowania decyzji, adaptacyjny, 39
- analiza systemowa, 2
- baza wiedzy, 25, 26, 44
- charakterystyka izokinetyczna, 77
- charakterystyka nieliniowa, 43
- ciąg uczący, 52, 53, 61, 65
- czas zakończenia, 47–50
- czas zakończenia, rozmyty, 50
- dekompozycja czasowa, 16
- dekompozycja przestrzenna, 16
- diagnostyka, 29, 39, 74, 79
- diagnoza, 26
- efektywność obliczeniowa, 44
- eksperyment identyfikacyjny, 38
- elektroterapia, 6
- funkcja konkluzji, 55
- funkcja przynależności, 40, 54
- funkcja przynależności, gaussowska, 55
- identyfikacja, 53, 64
- identyfikacja dwustopniowej, 10
- identyfikacja wielostopniowa, 16
- krioterapia, 6
- logika rozmyta, 44
- macierz stochastyczna, 46
- Markowa, łańcuch, 57–59, 61, 64, 68
- Markowa, sterowany łańcuch, 68, 69
- martyngał, 61
- metoda różnic czasowych, 52
- model ARX, 40
- model NARX, 40
- motoneuron, 29, 32
- niepełna informacja probabilistyczna, 61
- obiekt dwustopniowy, 25
- obiekt identyfikacji, dwustopniowy, 26

- obiekt statycznego, 7
- obiekt statyczny, 7
- obiekt złożony, 43, 45
- odwrotne zadanie dynamiki, 30
- opóźnienie neuromechaniczne, 32
- podjmowanie decyzji, proces wspomaganie, 7
- prędkość kontowa, 79
- proces niestacjonarny, 33
- programowanie dynamiczne, 51
- proste zadanie dynamiki, 30
- przestrzeń mierzalna, 57
- przestrzeń probabilistyczna, 57, 68
- Q-learning, 52
- różnica martyngałowa, 61
- reguła środka obszaru, 40, 55
- regulator, 53
- reprezentacja wiedzy, deklaratywna, 43
- reprezentacja wiedzy, proceduralna, 43
- rozpoznawania obiektów, zadanie, 28, 44, 53
- rozwiązanie przybliżone, 52
- scenariusz, 26, 28, 39, 45, 47, 52, 56, 67
- sterowanie, 16, 53
- sterowanie adaptacyjne, 43
- sterowanie ekstremalne, 65
- strojenie, 27, 39
- system doradczy, 2
- system dwustopniowy, 28
- system identyfikacji, hierarchiczny, 16
- system neuronowo-rozmyty, 54
- system neuronowo-rozmyty, rekurencyjny, 54
- system otwarty, 7
- system rozmyty, 53, 55, 56
- system Takagi-Sugeno, 56
- system wspomaganie podejmowania decyzji, 46
- system wspomaganie podejmowania decyzji, adaptacyjny, 39
- system zamknięty, 7
- systemy z reprezentacją wiedzy o obiekcie, 9
- systemy z reprezentacją wiedzy o podejmowaniu decyzji, 9
- sztuczna inteligencja, 45
- układ kostno-szkieletowy kończyny górnej, 29
- układ nerwowy, 29
- urządzenie diagnozujące, 26
- urządzenie wspomagające podejmowanie decyzji, 26, 66
- urządzenie wykonawcze, 26
- warstwa optymalizacji, 44
- warstwa sterowania niskopoziomowego, 44
- wartości własnych, wektor, 58
- wiedza eksperta, 9, 22, 43, 45, 53, 54
- wieloetapowe, zadanie wspomaganie podejmowania decyzji, 43
- wskaźnik jakości, 37, 38, 48–51, 66
- wspomaganie podejmowania decyzji, proces, 28, 34
- wspomaganie podejmowania decyzji, adaptacyjne, 28
- zadanie wspomaganie podejmowania decyzji, 16, 46, 51
- zadanie wspomaganie podejmowania decyzji z niejawnie zadanym czasem zakończenia, 46
- zadanie wspomaganie podejmowania decyzji z ustalonym z góry czasem zakończenia, 46
- zakłócenia addytywne, 60
- zakłócenia niemierzalne, 42
- zakłócenia pomiarowe, 44
- zbiór reguł, 44
- zbiór rozmyty, 53
- zbieżność według r -tego momentu, 59
- zbieżność według prawdopodobieństwa, 59
- zbieżność według rozkładu, 59
- zbieżność z prawdopodobieństwem 1, 59
- zespół mięśni szkieletowych, 29