

Teoria Sterowania

# Sterowanie inteligentne

**Ziemowit Dworakowski**  
Akademia Górniczo-Hutnicza,  
Katedra Robotyki i Mechatroniki

CONFIDENTIAL, Copyright: Ziemowit Dworakowski, zdw@agh.edu.pl

1

---

---

---

---

---

---

---

---

## Kiedy klasyczne metody nie zdają egzaminu?

Zakładaliśmy do tej pory wykorzystywanie układów:

- **Liniowych**
- **Stacjonarnych**
- **Bez dużego opóźnienia**
- **Prostych w identyfikacji**

Jak podejść do sterowania, gdy obiekt sterowania jest silnie nieliniowy, nie daje się zlinearyzować wokół punktu pracy i/lub jest niestacjonarny?

CONFIDENTIAL, Copyright: Ziemowit Dworakowski, zdw@agh.edu.pl

2

---

---

---

---

---

---

---

---

## Kiedy klasyczne metody nie zdają egzaminu?

Sztuczna inteligencja

**Inteligentna identyfikacja układów** (w tym budowa modeli układów nieliniowych oraz nadążanie za zmianami)

**Inteligentne sterowanie** (w tym adaptacyjne oraz pozwalające na kontrolę układów nieliniowych)

**Sterowanie rozmyte** (pozwalające na wykorzystanie doświadczenia eksperta)

- Ze względu na ograniczony zakres czasu na wykładzie i laboratoriach zajmiemy się wyłącznie pokazaniem wybranych przykładów oraz przedstawieniem ogólnej zasady działania metod. Nie będziemy rozważać układów nieliniowych (skupimy się na problemach niestacjonarnych), ale ogólna zasada działania przedstawianych rozwiązań pozostalaby ta sama również w przypadku pojawiania się nieliniowości w układzie sterowania.

CONFIDENTIAL, Copyright: Ziemowit Dworakowski, zdw@agh.edu.pl

3

---

---

---

---

---

---

---

---

## Teoria sterowania: sterowanie inteligentne

Sterowanie inteligentne to samodzielny moduł, oceniany osobno. W jego skład wchodzi:

### 4 instrukcje laboratoryjne:

- Ewolucyjna identyfikacja obiektu sterowania
- Ewolucyjna optymalizacja kontrolera PID
- Sterowanie predykcyjne z modelem opartym o sieć neuronową
- Sterowanie predykcyjne oraz optymalizacja ewolucyjna układów zmiennych w czasie

Oceniane jak na PSIWSUM/PSIWMUM: Im więcej zadań zrobionych na zajęciach, tym wyższa ocena. Instrukcje oraz materiały do zajęć do pobrania z <http://galaxy.agh.edu.pl/~zdw/Materials/CT/>

### 1 test

Na 1 zajęciach w ramach modułu. Możliwy do poprawy 2 razy. Wymagany zakres wiedzy obejmuje niniejszy wykład.

Ocena końcowa z modułu stanowi średnią ważoną ocen z instrukcji z wagą 1 oraz testu z wagą 2. Aby uzyskać zaliczenie modułu, wszystkie oceny muszą być pozytywne.

CONFIDENTIAL, Copyright: Ziemowit Dworakowski, zdw@agh.edu.pl

4

---

---

---

---

---

---

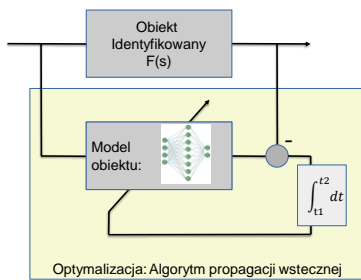
---

---

---

---

## Identyfikacja neuronowa



+ **Możliwość identyfikacji nieliniowości**

+ **Obiekt identyfikowany nie musi być wyłączany z użytkowania**

+ **Szybka nauka**

+ **Możliwość łatwej adaptacji (cykliczne douczanie sieci)**

- **Reprezentacja nie jest intuicyjna**

- **Brak możliwości dalszego badania zidentyfikowanego obiektu (np. stabilności)**

CONFIDENTIAL, Copyright: Ziemowit Dworakowski, zdw@agh.edu.pl

5

---

---

---

---

---

---


---

---

---

---

## Identyfikacja ewolucyjna



+ **Zachowujemy intuicyjną reprezentację (w tym możliwość jej dalszych badań)**

+ **Obiekt identyfikowany nie musi być wyłączany z użytkowania**

+ **Możliwość łatwej adaptacji**

- **Problem złożony obliczeniowo**

- **Konfiguracja AG jest trudna**

CONFIDENTIAL, Copyright: Ziemowit Dworakowski, zdw@agh.edu.pl

6

---

---

---

---

---

---

---

---

---

---

### Identyfikacja w problemach niestacjonarnych

Co w przypadku, gdy obiekt zmienia się w czasie?

Reprezentacja powinna pozwalać na łatwą adaptację do nowych warunków (zmiany są zazwyczaj płynne, nie ma potrzeby identyfikowania „od zera”)

CONFIDENTIAL, Copyright: Ziemowit Dworakowski, zdw@agh.edu.pl

7

---

---

---

---

---

---

---

---

---

---

### Optymalizacja adaptacyjna

Mamy dwa rodzaje zmian funkcji celu  
– zazwyczaj występujące jednocześnie, w różnym stopniu:

Objective function value

Parameter value

Przesunięcie funkcji

Zmiana wartości

Częste poprawki (np. z wykorzystaniem algorytmu gradientowego startując od poprzedniego minimum globalnego)

Dobrze by było śledzić położenie wielu minimów lokalnych jednocześnie...

CONFIDENTIAL, Copyright: Ziemowit Dworakowski, zdw@agh.edu.pl

8

---

---

---

---

---

---

---

---

---

---

### Optymalizacja adaptacyjna

**Wymagania:**

- AG powinien utrzymać populację w wielu minimach jednocześnie → Spora populacja, niski nacisk selektywny, być może dodatkowe podtrzymanie różnorodności
- AG powinien nadążać za zmianami położenia minimów → Krok mutacji nigdy nie zbliża się do zera. Po początkowym przeszukaniu przestrzeni i uzyskaniu konwergencji krok pozostaje na stałym poziomie
- AG powinien zachowywać zdolności eksploracyjne przez cały czas trwania optymalizacji (zdolność do znajdowania nowych minimów) → Część populacji jest generowana losowo lub też mutowana z zastosowaniem relatywnie dużego kroku mutacji

CONFIDENTIAL, Copyright: Ziemowit Dworakowski, zdw@agh.edu.pl

9

---

---

---

---

---

---

---

---

---

---

## Alternatywa: Elastyczny genom

Jeśli osobnik znajduje się **w pobliżu** minimum lokalnego, tylko **mały** zakres mutacji umożliwi poprawę rezultatu

Jeśli osobnik znajduje się **daleko** od minimum lokalnego, tylko **duży** zakres mutacji umożliwi poprawę rezultatu



*Odwróćmy wnioskowanie...*

Skoro osobnika wygenerowano **małym** zakresem mutacji a poprawił rezultat, znajduje się **w pobliżu** minimum lokalnego

Skoro osobnika wygenerowano **dużym** zakresem mutacji a poprawił rezultat, znajduje się **daleko** od minimum lokalnego

CONFIDENTIAL, Copyright: Ziemowit Dworakowski, zdw@agh.edu.pl

10

---

---

---

---

---

---

---

---

---



---

---

---

## Alternatywa: Elastyczny genom

Niech zakres mutacji nie będzie zależny od czasu, ale znajdzie się w genomie, jako kolejny gen



CONFIDENTIAL, Copyright: Ziemowit Dworakowski, zdw@agh.edu.pl

11

---

---

---

---

---

---

---

---

---

---

---

---

## Optymalizacja adaptacyjna

### Jak budować genotyp?

Wiedza kontekstowa: co wiemy o obiekcie? Czy dopuszczamy obiekty niestabilne? Czy znamy rząd układu albo ogólną postać transmitancji?

Czy jesteśmy w stanie wygenerować początkową populację tak, by nie było konieczności odrzucania obiektów nie spełniających oczywistych wymagań?

A może umożliwić AG zbudowanie własnej reprezentacji (również ewolucyjnie?)

CONFIDENTIAL, Copyright: Ziemowit Dworakowski, zdw@agh.edu.pl

12

---

---

---

---

---

---

---

---

---

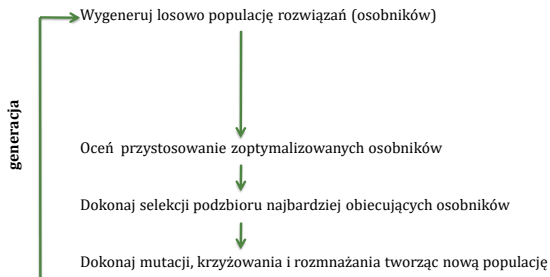
---

---

---

## Algorytm memetyczny (hybrydowy, lamarkowski)

### Podstawowy algorytm genetyczny



*Powtarzaj dopóki nie skończy się czas lub algorytm nie przestanie poprawiać rozwiązań*

CONFIDENTIAL, Copyright: Ziemowit Dworakowski, zdw@agh.edu.pl

13

---

---

---

---

---

---

---

---

## Algorytm memetyczny (hybrydowy, lamarkowski)

### Podstawowy algorytm memetyczny (hybrydowy, lamarkowski)

#### Zalety:

- Wymagana mniejsza populacja
- Nadążanie za zmianami funkcji celu staje się dużo prostsze

#### Wady:

- Jeszcze większa ilość metaparametrów do konfiguracji
- Skomplikowany w implementacji
- Zazwyczaj wymaga więcej mocy obliczeniowej od klasycznego AG

CONFIDENTIAL, Copyright: Ziemowit Dworakowski, zdw@agh.edu.pl

14

---

---

---

---

---

---

---

---

## Sterowanie adaptacyjne

CONFIDENTIAL, Copyright: Ziemowit Dworakowski, zdw@agh.edu.pl

15

---

---

---

---


---

---

---

---

## Dlaczego tym razem nie będzie już tak łatwo?



- Obiekt sterowany znajduje się **wewnątrz** pętli optymalizacyjnej: Pojawia się konieczność nadążania za jego zmianami dużo szybciej

- Nie możemy pozwolić sobie na testowanie dowolnych parametrów: Destabilizacja obiektu będzie miała realne konsekwencje.

CONFIDENTIAL, Copyright: Ziemowit Dworakowski, zdw@agh.edu.pl

16

---

---

---

---

---

---

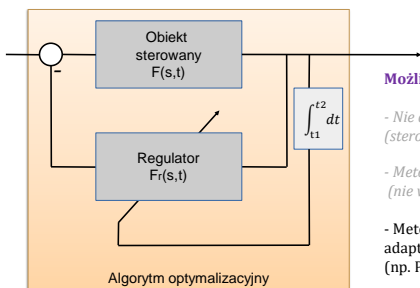
---

---

---

---

## Dlaczego tym razem nie będzie już tak łatwo?



### Możliwe podejścia:

- Nie adaptujemy w ogóle (sterowanie odporne)

- Metody klasyczne (nie wykorzystujące AI)

- Metody bazujące na ewolucyjnej adaptacji prostych regulatorów (np. PID)

- Adaptacyjne sterowanie predykcyjne

- ...

CONFIDENTIAL, Copyright: Ziemowit Dworakowski, zdw@agh.edu.pl

17

---

---

---

---

---

---

---

---

---

---

## Ewolucja regulatorów

- Jako punkt wyjściowy potrzebny jest „w miarę dobry” regulator – np. PID (aby zapewnić poprawną regulację od samego początku)
- Obiekt musi być „łatwy w regulacji” – zmiany obiektu muszą być powolne aby zapewnić możliwość nadążania za nimi
- Funkcja celu nie powinna posiadać wielu minimów lokalnych (przejście od dowolnego regulatora początkowego do położenia optymalnego powinno być możliwe na drodze ciągłych niewielkich poprawek)
- Obiekt musi być stabilny (tj. odłączenie regulatora nie powinno stanowić zagrożenia dla obiektu)

CONFIDENTIAL, Copyright: Ziemowit Dworakowski, zdw@agh.edu.pl

18

---

---

---

---

---

---

---

---

---

---

## Rozwiązanie na bazie algorytmu 1+1

Zamknij pętlę sprzężenia zwrotnego używając regulatora PID o niewielkich wartościach stałych

Oceń działanie regulatora, jeśli kryterium jakości jest jak do tej pory najlepsze, zapamiętaj parametry regulatora

Zmodyfikuj parametry regulatora poprzez **niewielki** krok w losowym kierunku od zapamiętanych parametrów

CONFIDENTIAL, Copyright: Ziemowit Dworakowski, zdw@agh.edu.pl

19

---

---

---

---

---

---



---

---

---

---

## Rozwiązanie na bazie algorytmu 1+1



CONFIDENTIAL, Copyright: Ziemowit Dworakowski, zdw@agh.edu.pl

20

---

---

---

---

---

---

---

---

---

---

## Rozwiązanie na bazie algorytmu 1+1

+ Algorytm 1+1 (w przeciwieństwie do pełnego AG) zapewnia na tyle szybką konwergencję, że w korzystnych warunkach może nadążyć za zmianami obiektu

ALE:

- Konieczność uśredniania wskazań (jeśli nie mamy możliwości pełnego monitorowania wejść) powoduje znaczne spowolnienie konwergencji
- Im szybciej obiekt się zmienia, tym bardziej trzeba skrócić okno z którego wybierane jest rozwiązanie do modyfikacji: możliwe dalsze spowolnienie konwergencji

CONFIDENTIAL, Copyright: Ziemowit Dworakowski, zdw@agh.edu.pl

21

---

---

---

---

---

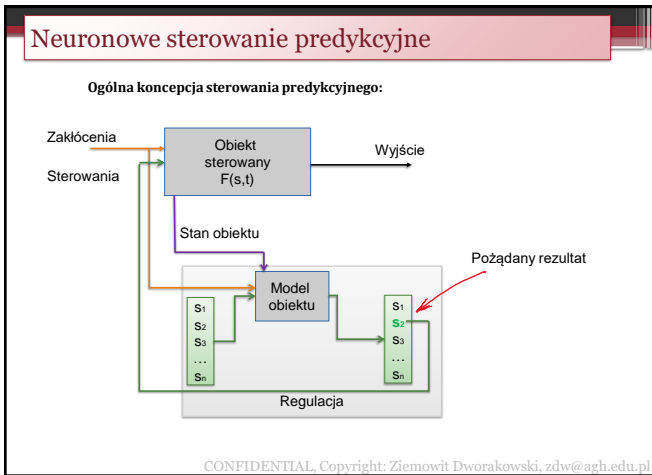
---

---

---

---

---



22

---

---

---

---

---

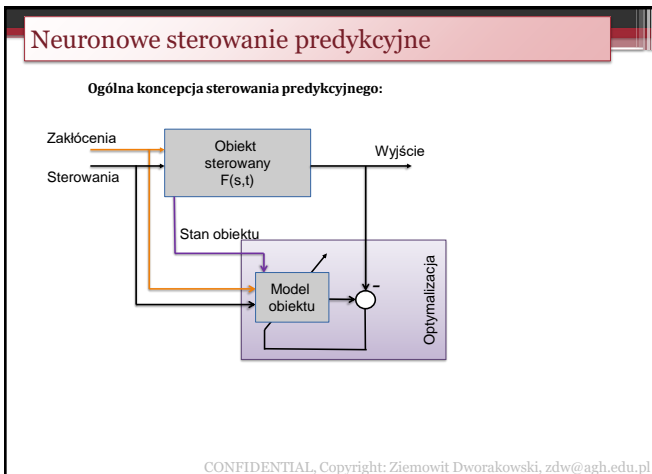
---

---

---

---

---



23

---

---

---

---

---

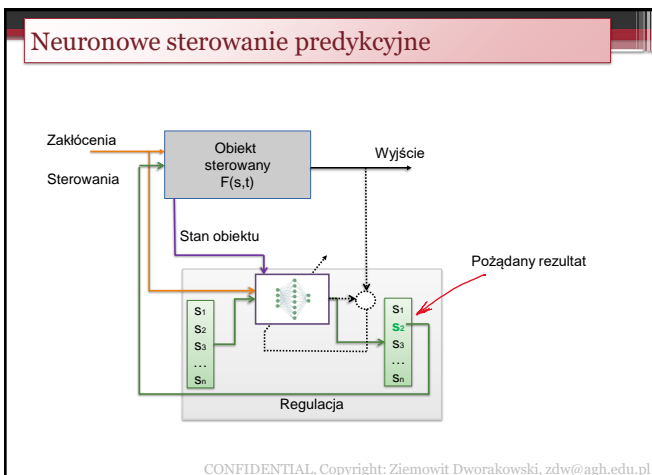
---

---

---

---

---



24

---

---

---

---

---

---

---

---

---

---



## Neuronowe sterowanie predykcyjne

1. Uczymy sieć neuronową do przewidywania zachowania układu w zależności od obserwowanych sterowań, pozostałych wejść oraz stanu układu
2. Podajemy do sieci neuronowej różne możliwe sterowania wybierając ostatecznie to, które minimalizuje wybrane kryterium jakościowe dla danego stanu układu oraz pozostałych wejść
3. Używamy wybranego sterowania w rzeczywistym układzie
4. Co jakiś czas dotrenowujemy sieć na podstawie nowo zebranych danych

CONFIDENTIAL, Copyright: Ziemowit Dworakowski, zdw@agh.edu.pl

25

---

---

---

---


---

---

---

---

## Neuronowe sterowanie predykcyjne



- + Szybka adaptacja
- + Duża skuteczność w przypadku systemów nieliniowych
- Konieczność monitorowania stanu obiektu
- Brak gwarancji stabilności układu
- Brak możliwości analizy zależności długoterminowych

CONFIDENTIAL, Copyright: Ziemowit Dworakowski, zdw@agh.edu.pl

26

---

---

---

---


---

---

---

---

## Zastosowanie sieci rekurencyjnych



- + Szybka adaptacja
- + Duża skuteczność w przypadku systemów nieliniowych
- Konieczność monitorowania stanu obiektu
- Brak gwarancji stabilności układu

CONFIDENTIAL, Copyright: Ziemowit Dworakowski, zdw@agh.edu.pl

27

---

---

---

---

---

---

---

---

*Teoria Sterowania*

## Sterowanie inteligentne

- 1) Jak działa genetyczna identyfikacja układu sterowania?
- 1) Jak dostosować działanie AG do optymalizacji problemów zmiennych w czasie (optymalizacji adaptacyjnej)?
- 1) Jak działa adaptacyjna optymalizacja sterownika PID (np. z zastosowaniem metody 1+1)?
- 1) Jak działa neuronowe sterowanie predycyjne?

CONFIDENTIAL, Copyright: Ziemowit Dworakowski, zdw@agh.edu.pl

28

---

---

---

---

---

---

---

---