

# Wybrane problemy nawigacji autonomicznej

**Piotr Skrzypczyński**

*Instytut Automatyki i Inżynierii Informatycznej*

*Politechnika Poznańska*

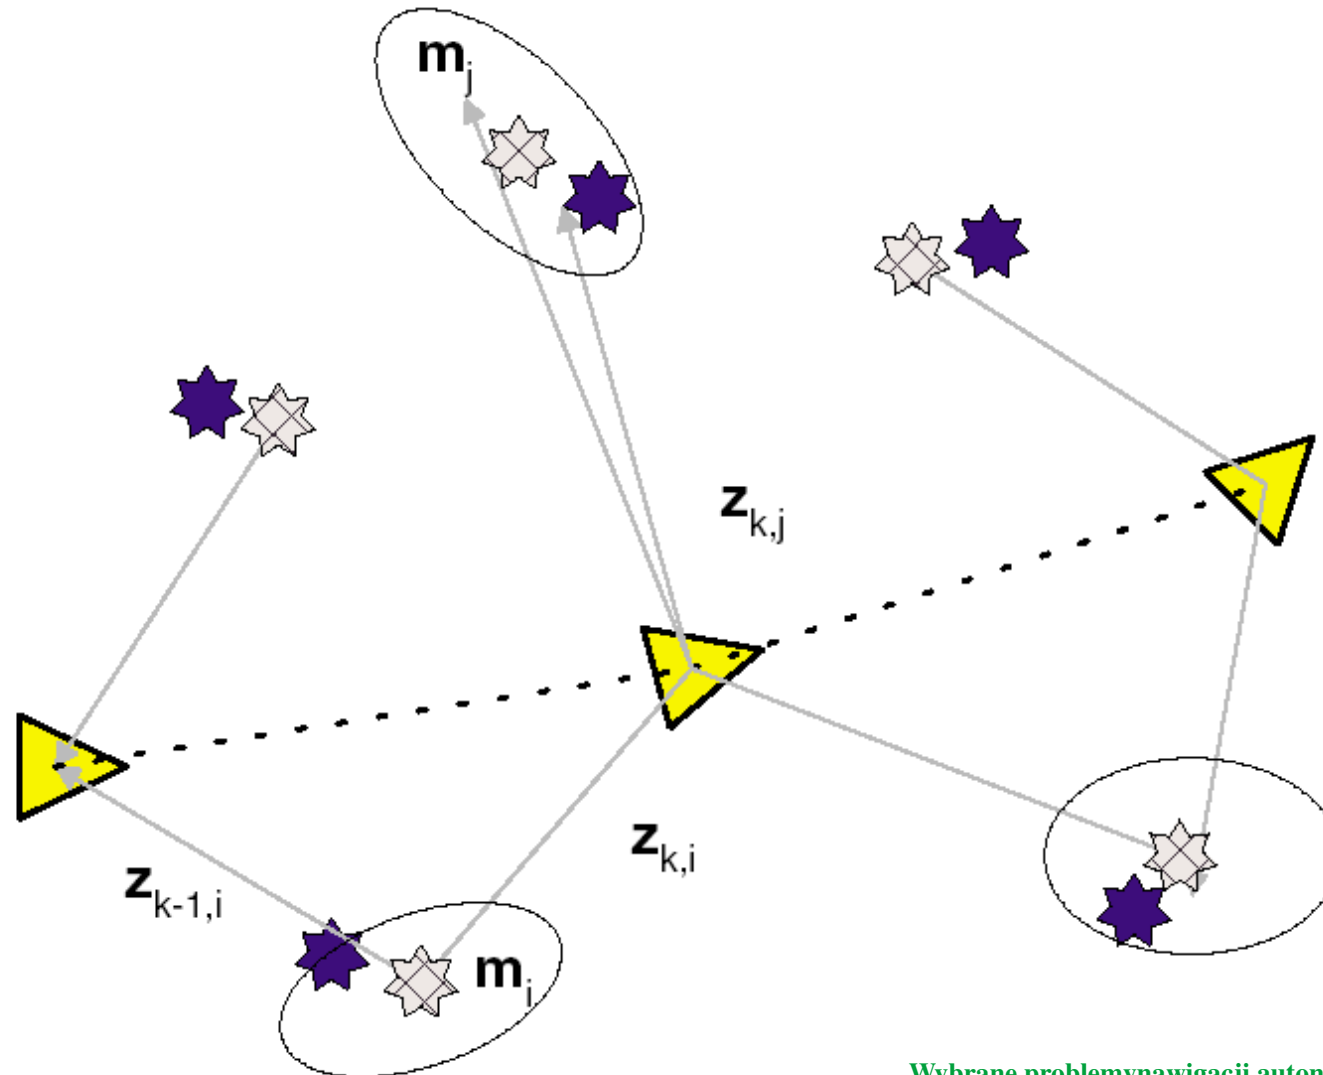


# Wstęp

- Robot mobilny – podstawową funkcją jest przemieszczanie się względem otoczenia (lokomocja).
- Nawigacja (łac. *navigatio* – żegluga) jest umiejętnością określenia własnej pozycji i kursu (drogi) do celu na podstawie mapy.
  - budowa modelu otoczenia,
  - określanie swojej pozycji względem otoczenia,
  - planowanie i monitorowanie wykonania sekwencji ruchów prowadzących do osiągnięcia celu.


# Budowa mapy

Ilustracja zadania budowy mapy (złożonej z cech) przy znanej pozycji robota.




# Samolokalizacja

Ilustracja zadania samolokalizacji (śledzenia pozycji) przy znanej mapie.



# Samolokalizacja i budowa mapy

Ilustracja zadania jednoczesnej samolokalizacji i budowy mapy.



# Nawigacja

- Zadanie nawigacji robota: określenie własnej pozycji i drogi do celu na podstawie mapy.
- Nawigacja ze znaną mapą jest zadaniem względnie łatwym (algorytmicznie).
- Włączenie tworzenia mapy do zadania nawigacji: *Simultaneous Localization and Mapping*.
- SLAM jest zadaniem trudnym algorytmicznie i praktycznie.

# Nawigacja

- Zadanie nawigacji robota: określenie własnej pozycji i drogi do celu na podstawie mapy.
- Nawigacja ze znaną mapą jest zadaniem względnie łatwym (algorytmicznie).
- Włączenie tworzenia mapy do zadania nawigacji: *Simultaneous Localization and Mapping*.
- SLAM jest zadaniem trudnym algorytmicznie i praktycznie.

# SLAM: koncepcja

Jaka pozycja robota  $\mathbf{x}_{R(k)}$  i mapa otoczenia  $\mathbf{m}_{(k)}$  są najbardziej prawdopodobne w świetle zgromadzonych pomiarów i sterowań zrealizowanych do chwili  $k$  ?

Funkcja gęstości prawdopodobieństwa *a posteriori* w chwili  $k$ :

$$p(\mathbf{x}_{R(k)}, \mathbf{m}_{(k)} \mid \mathbf{z}^k, \mathbf{u}^k).$$

Ogólne rozwiązanie problemu SLAM – rekursywny filtr Bayesa:

$$\begin{aligned} p(\mathbf{x}_{R(k)}, \mathbf{m} \mid \mathbf{z}^k, \mathbf{u}^k) = & \underbrace{\eta p(\mathbf{z}_{(k)} \mid \mathbf{x}_{R(k)}, \mathbf{m})}_{\text{model obserwacji}} \int \underbrace{p(\mathbf{x}_{R(k)} \mid \mathbf{x}_{R(k-1)}, \mathbf{u}_{(k)})}_{\text{model systemu}} \\ & \underbrace{p(\mathbf{x}_{R(k-1)}, \mathbf{m} \mid \mathbf{z}^{k-1}, \mathbf{u}^{k-1})}_{\text{poprzedni stan}} d\mathbf{x}_{R(k-1)}. \end{aligned}$$



# SLAM: koncepcja

Jaka pozycja robota  $\mathbf{x}_{R(k)}$  i mapa otoczenia  $\mathbf{m}_{(k)}$  są najbardziej prawdopodobne w świetle zgromadzonych pomiarów i sterowań zrealizowanych do chwili  $k$  ?

Rozkład normalny:

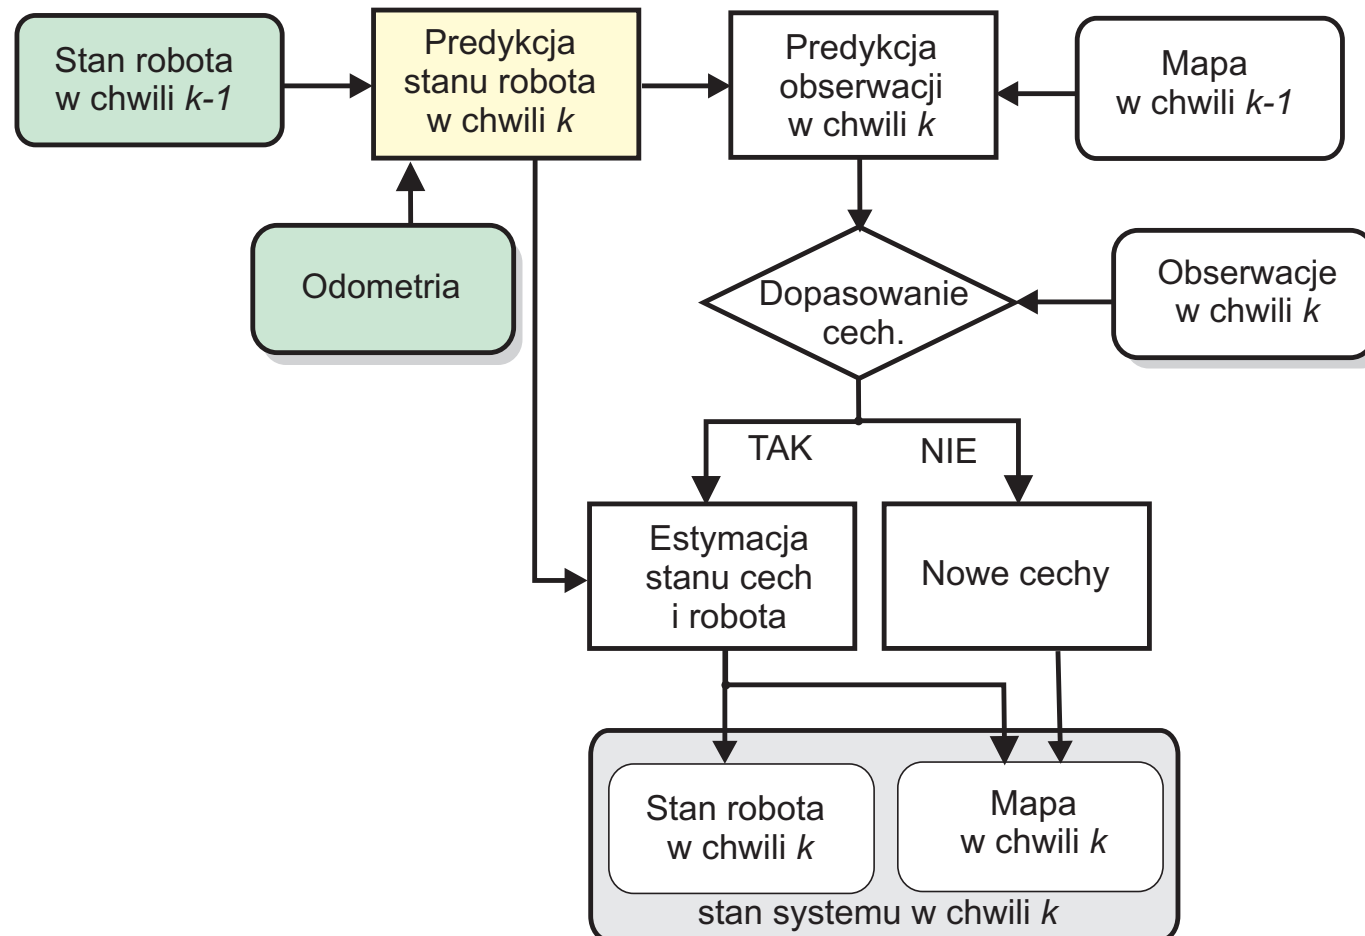
$$p(\mathbf{x}_{R(k)}, \mathbf{m} \mid \mathbf{z}^k, \mathbf{u}^k) \sim N(\hat{\mathbf{x}}_{(k)}, \mathbf{C}_x).$$

Struktura rozwiązania z użyciem EKF:

$$p(\mathbf{x}_{R(k)}, \mathbf{m} \mid \mathbf{z}^k, \mathbf{u}^k) = \underbrace{\eta \left( \int p(\mathbf{x}_{R(k)} \mid \mathbf{x}_{R(k-1)}, \mathbf{u}_k) p(\mathbf{x}_{R(k-1)}, \mathbf{m} \mid \mathbf{z}^{(k-1)}, \mathbf{u}^{(k-1)}) d\mathbf{x}_{R(k-1)} \right)}_{\text{etap korekcji}} \underbrace{\quad}_{\text{etap predykcji}}$$

# EKF-SLAM: koncepcja

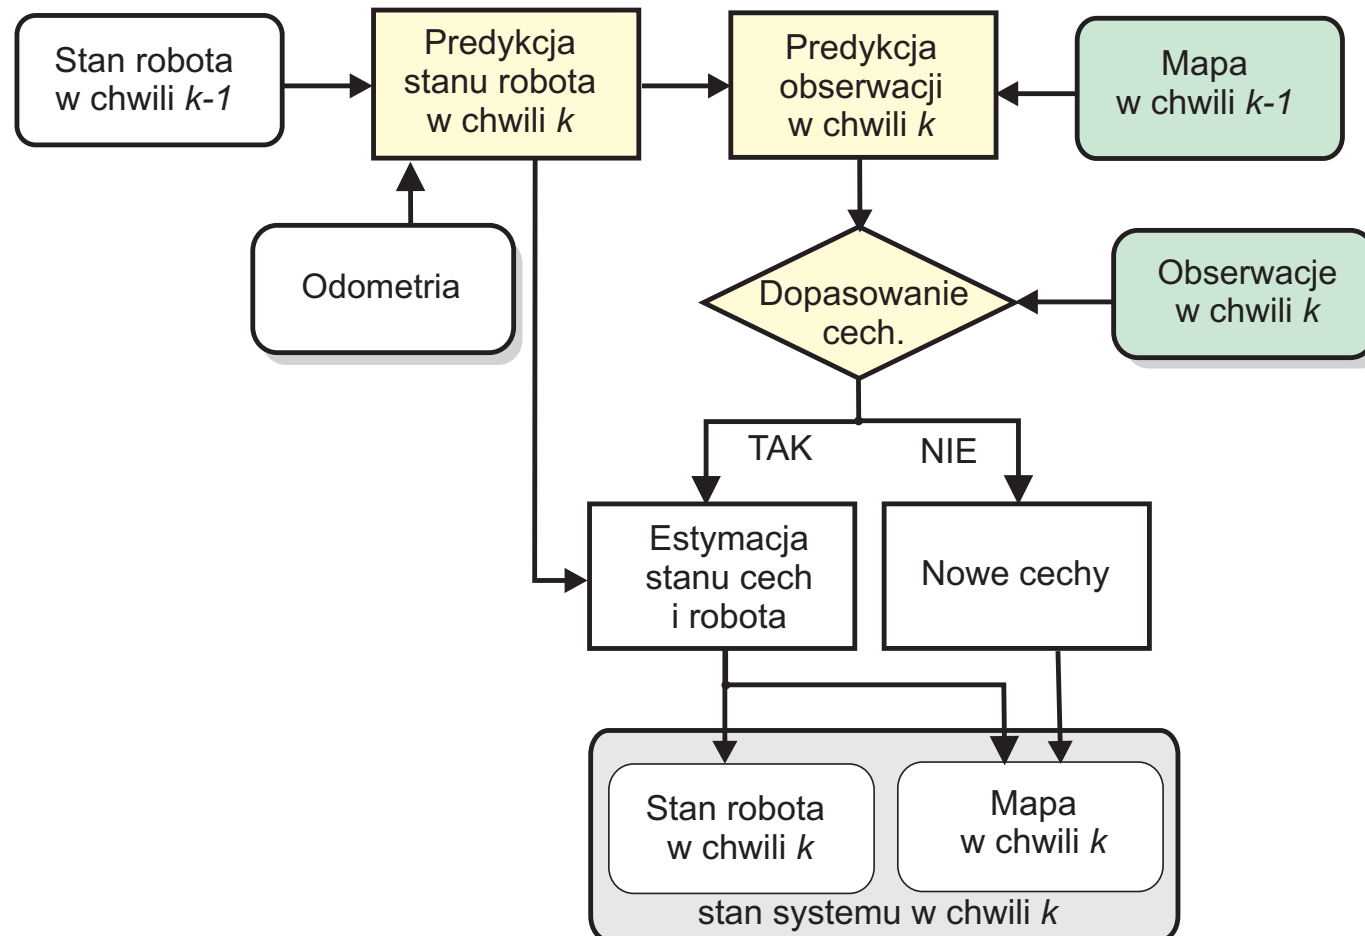
## Schemat blokowy systemu SLAM opartego na EKF



Etap predykcji EKF – określenie pozycji robota na podstawie odometrii.

# EKF-SLAM: koncepcja

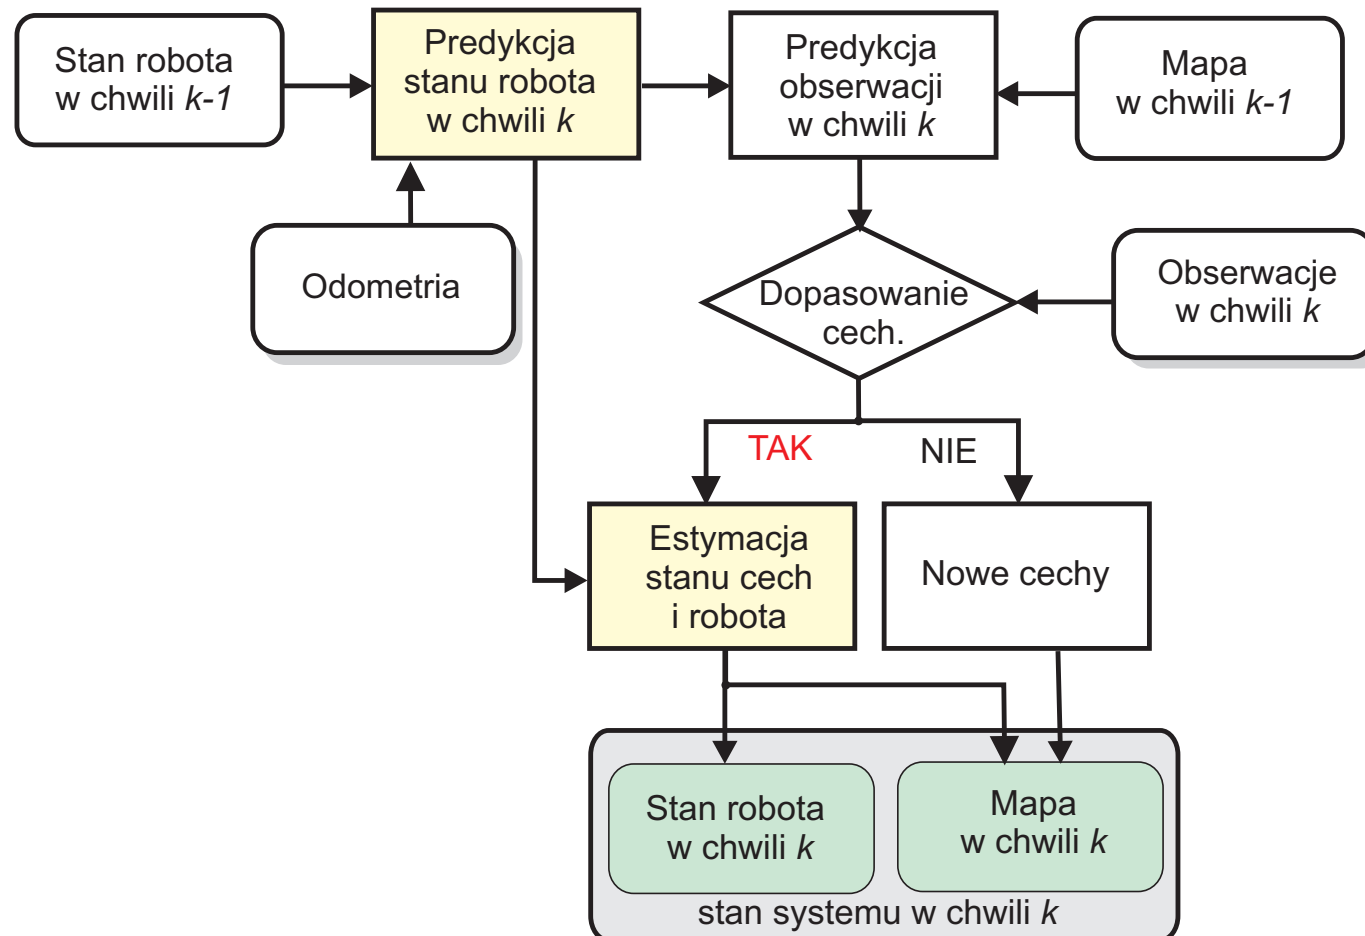
## Schemat blokowy systemu SLAM opartego na EKF



Etap predykcji EKF – dopasowanie spodziewanych cech do cech wyodrębnionych z pomiarów.

# EKF-SLAM: koncepcja

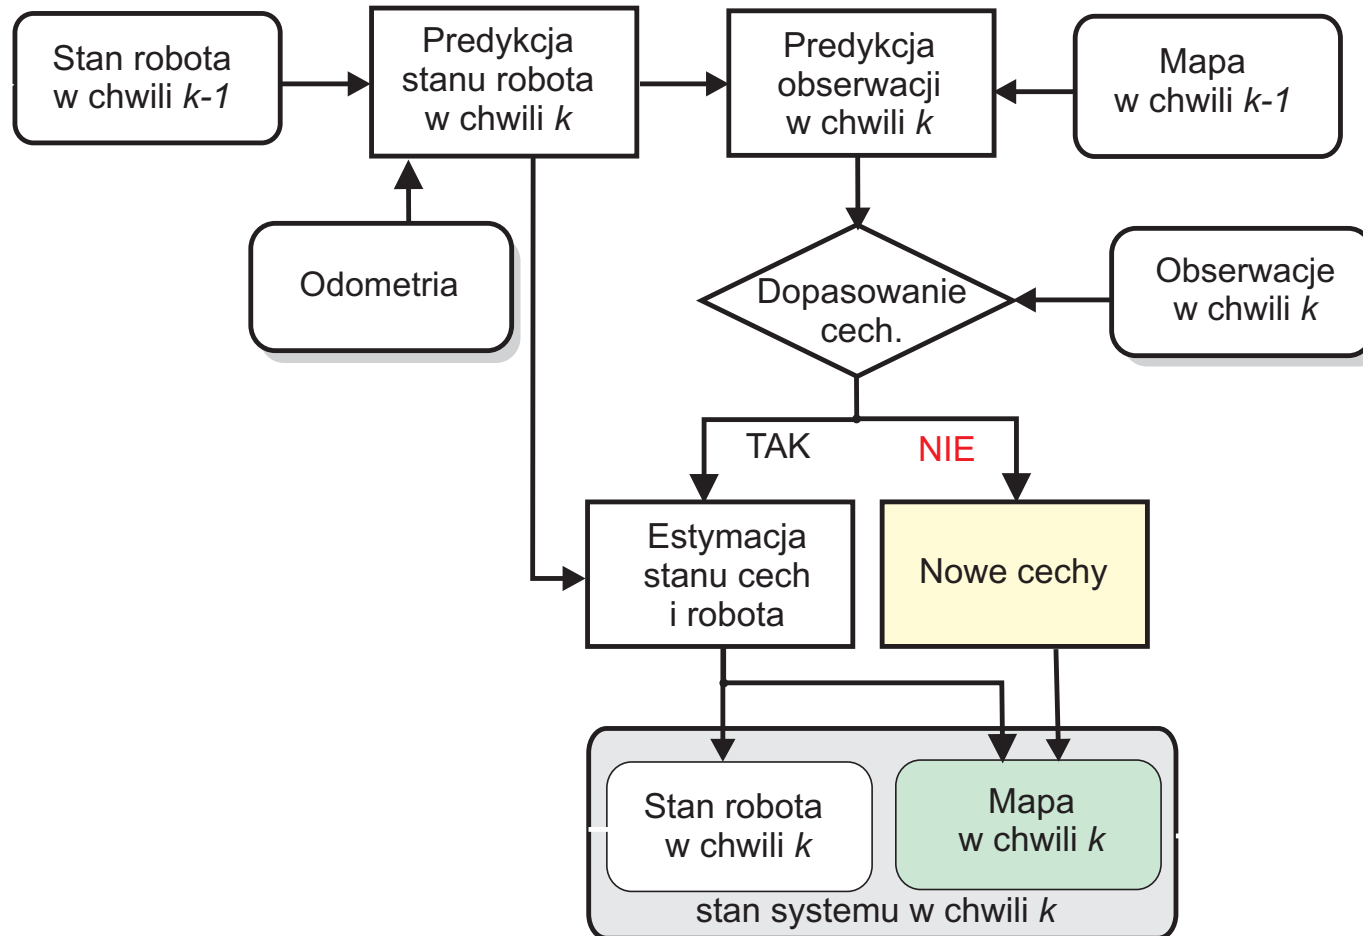
Schemat blokowy systemu SLAM opartego na EKF



Etap korekcji EKF – uaktualnienie pozycji robota i parametrów cech.

# EKF-SLAM: koncepcja

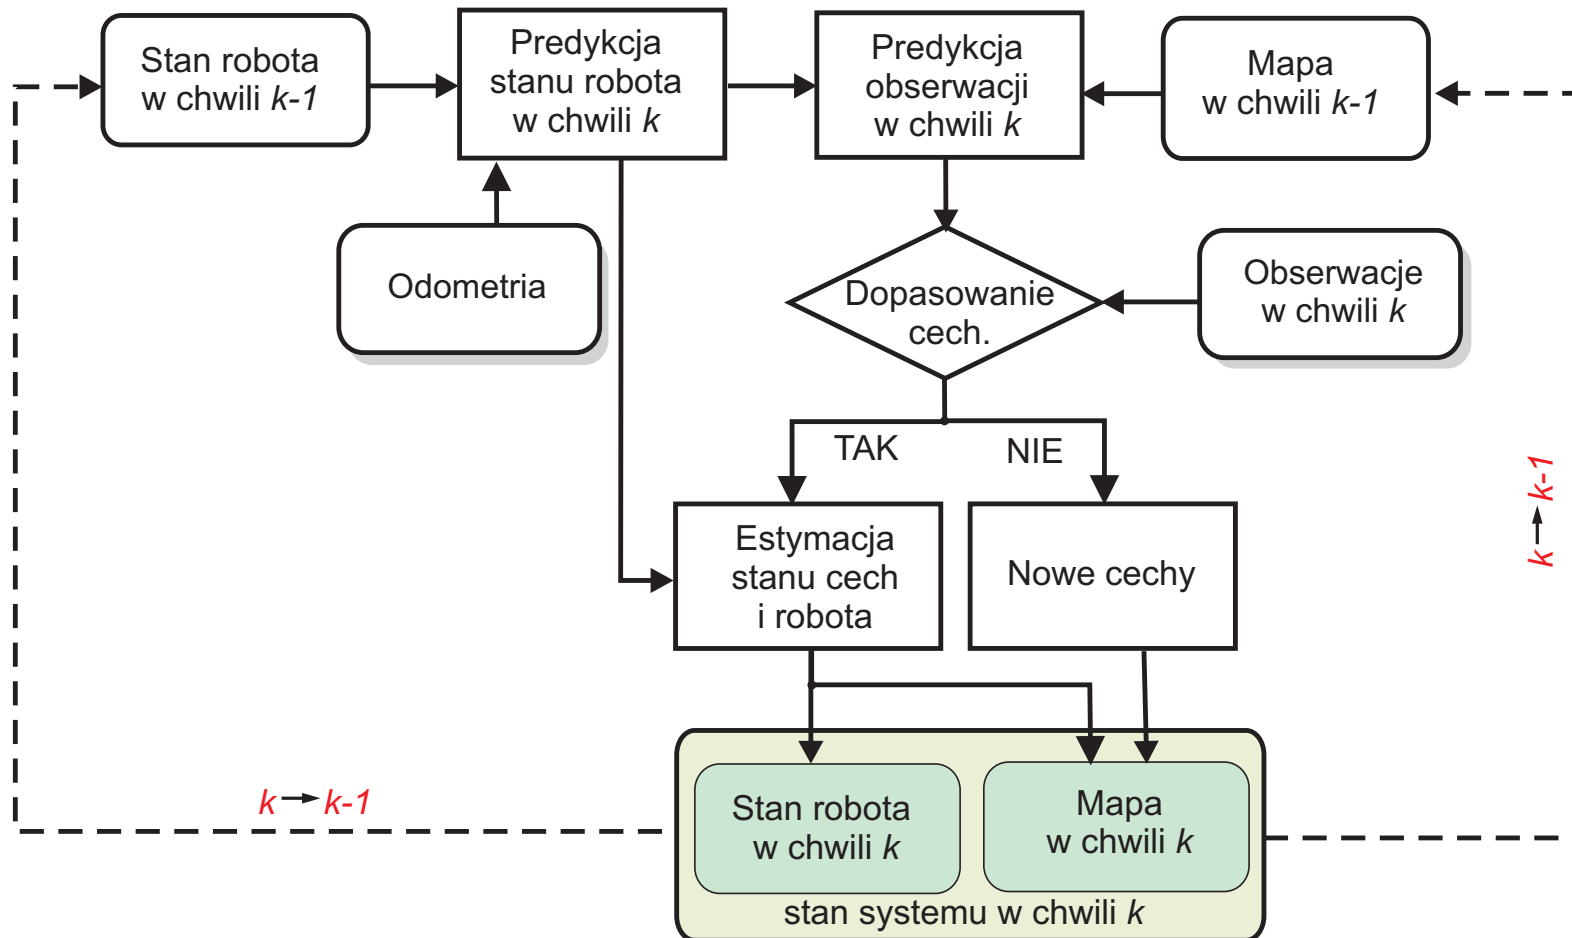
Schemat blokowy systemu SLAM opartego na EKF



Dodawanie nowych cech do mapy – rozbudowa wektora stanu.

# EKF-SLAM: koncepcja

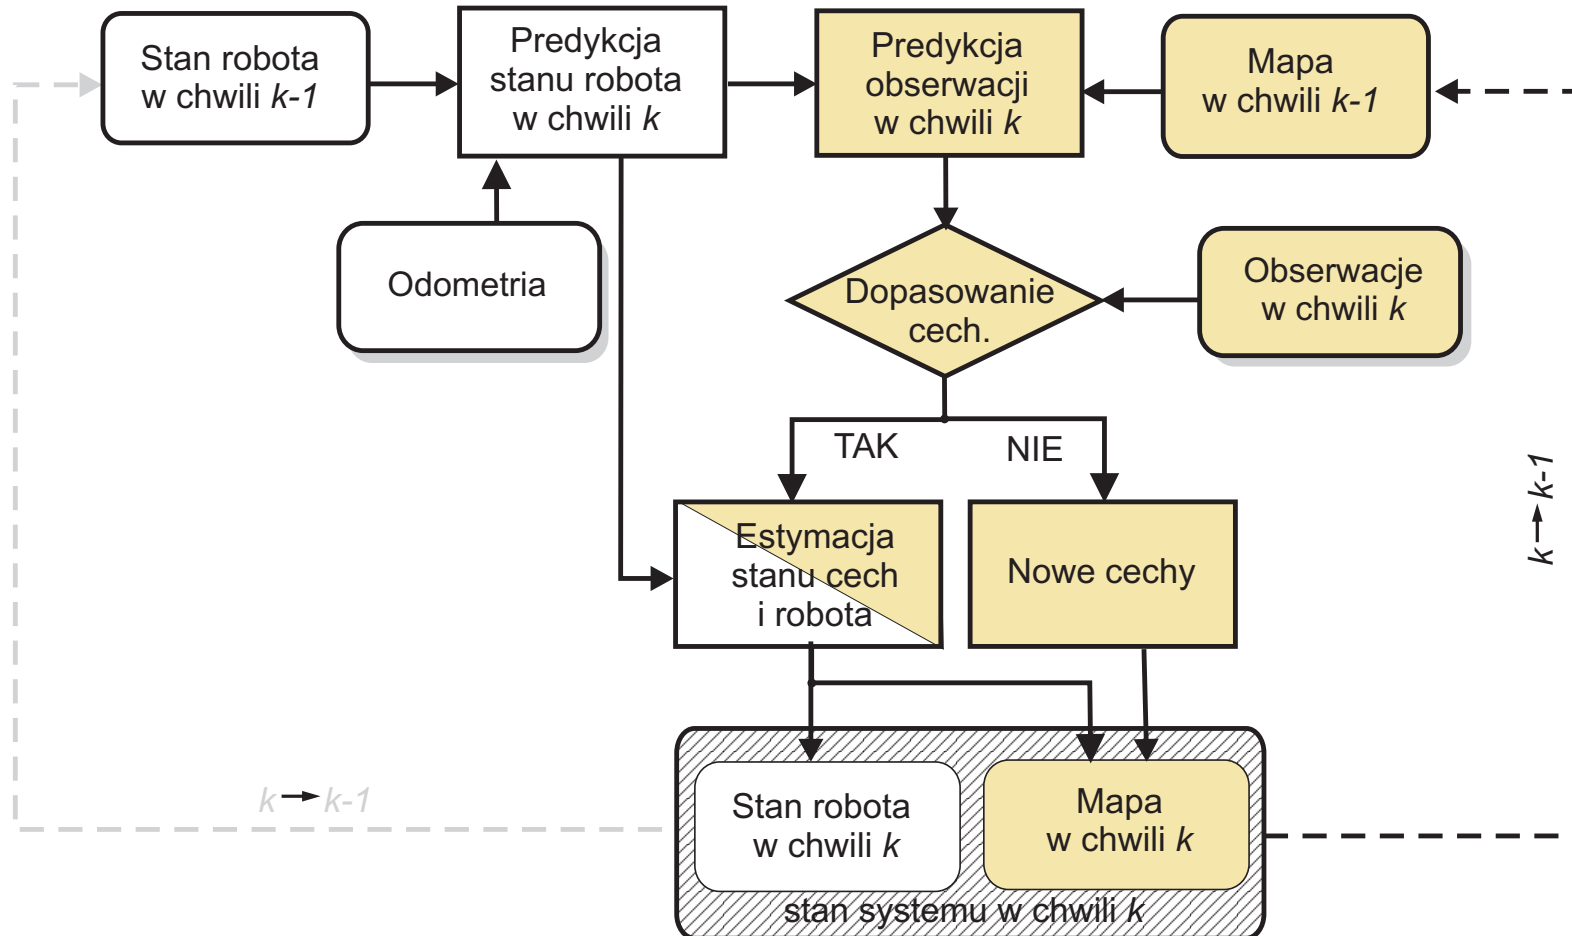
Schemat blokowy systemu SLAM opartego na EKF



Stan systemu w chwili obecnej staje się stanem w chwili poprzedniej.

# EKF-SLAM: koncepcja

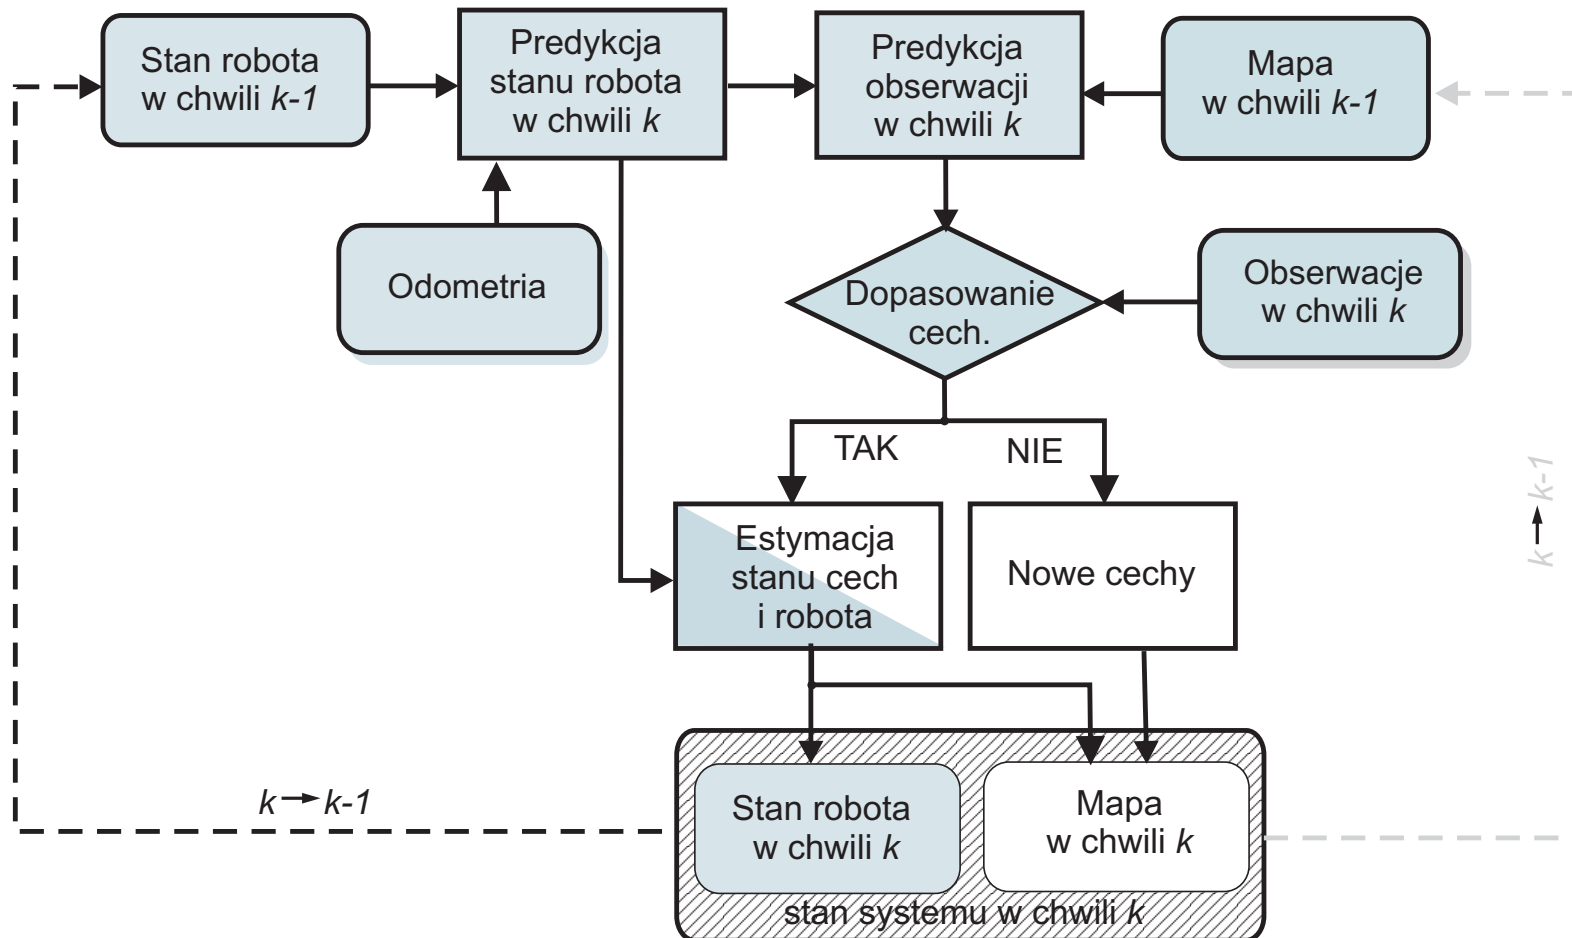
Schemat blokowy systemu SLAM opartego na EKF



Budowa mapy przy znanej pozycji robota.

# EKF-SLAM: koncepcja

Schemat blokowy systemu SLAM opartego na EKF

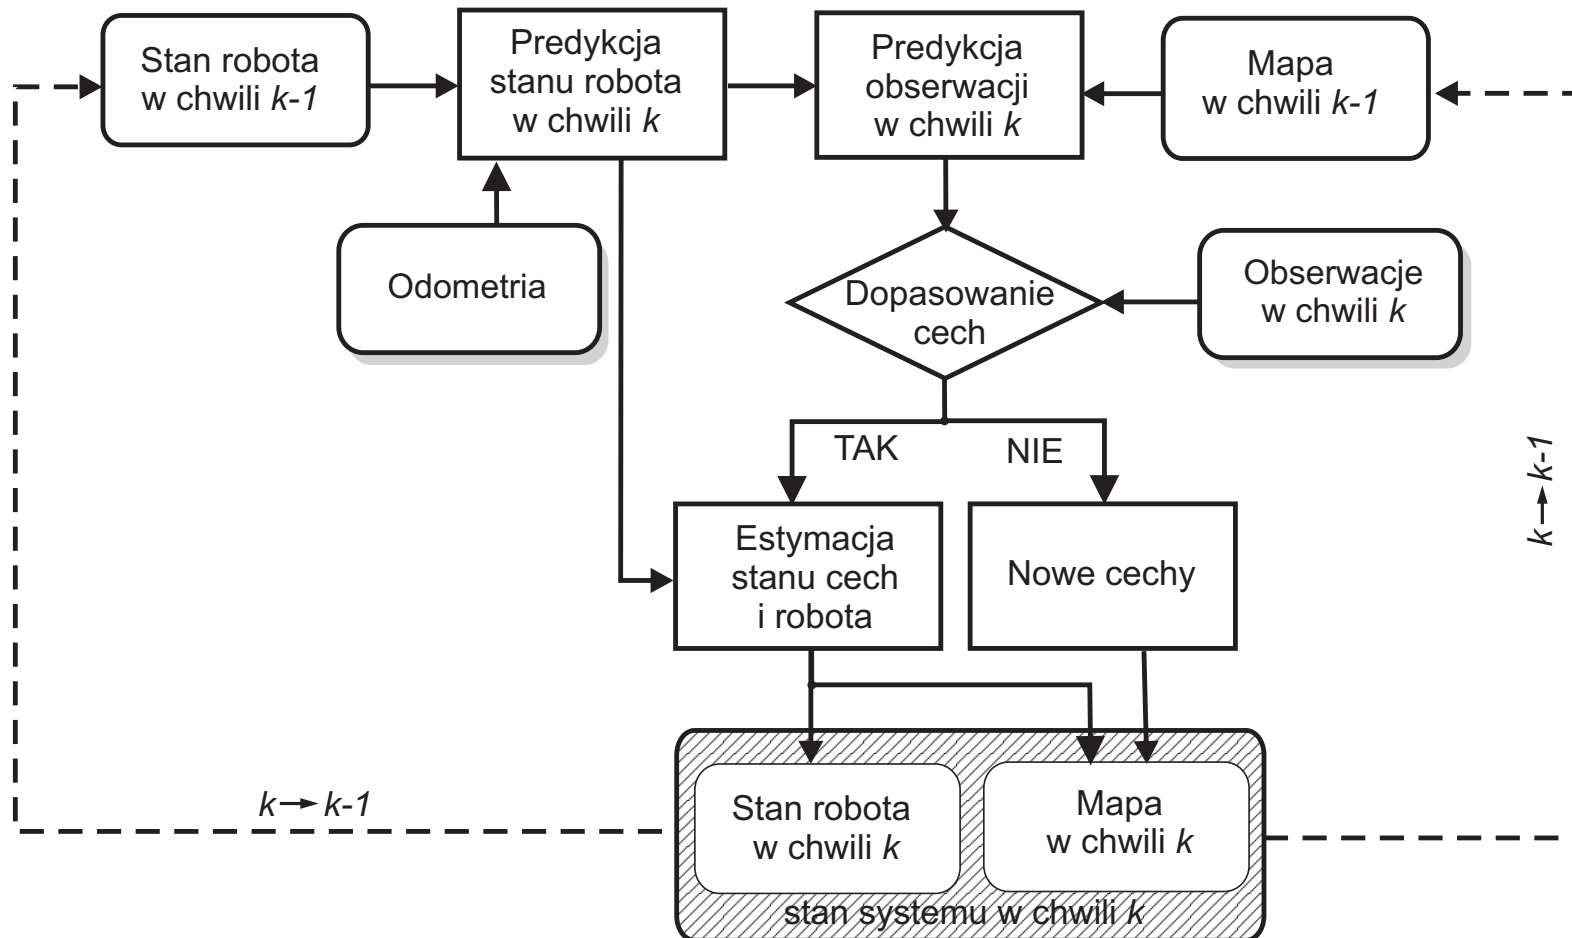


Samolokalizacja (*pose tracking*) ze znaną mapą.



# EKF-SLAM: koncepcja

Schemat blokowy systemu SLAM opartego na EKF



**W zagadnieniu SLAM stan robota i mapa otoczenia muszą być estymowane jednocześnie.**

# RGB-D SLAM (3D)

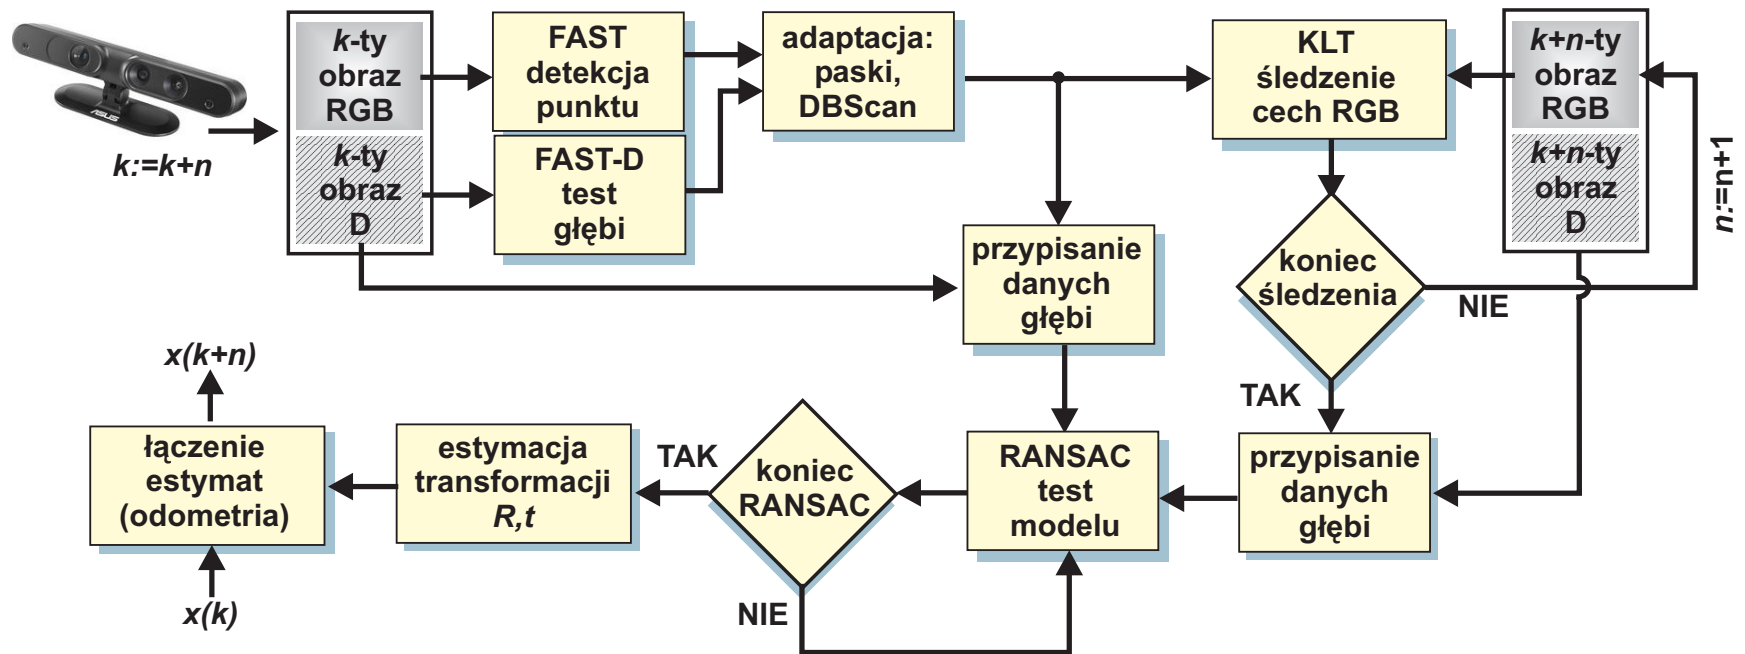
- Pewne klasy robotów wymagają samolokalizacji w 3D, względem sześciu stopni swobody:

$$\mathbf{x}_R = [x_r \ y_r \ z_r \ \theta_r \ \phi_r \ \psi_r]^T$$

- Pojawienie się sensorów RGB-D spowodowało szybki rozwój nowych metod SLAM i VO.
- Algorytm VO – określa przemieszczenie robota na podstawie informacji wizyjnej bez tworzenia mapy otoczenia.
- RGB-D SLAM jako problem optymalizacji grafu pozycji sensora.
- RGB-D SLAM jako problem optymalizacji grafu pozycji sensora oraz cech (*bundle adjustment*).

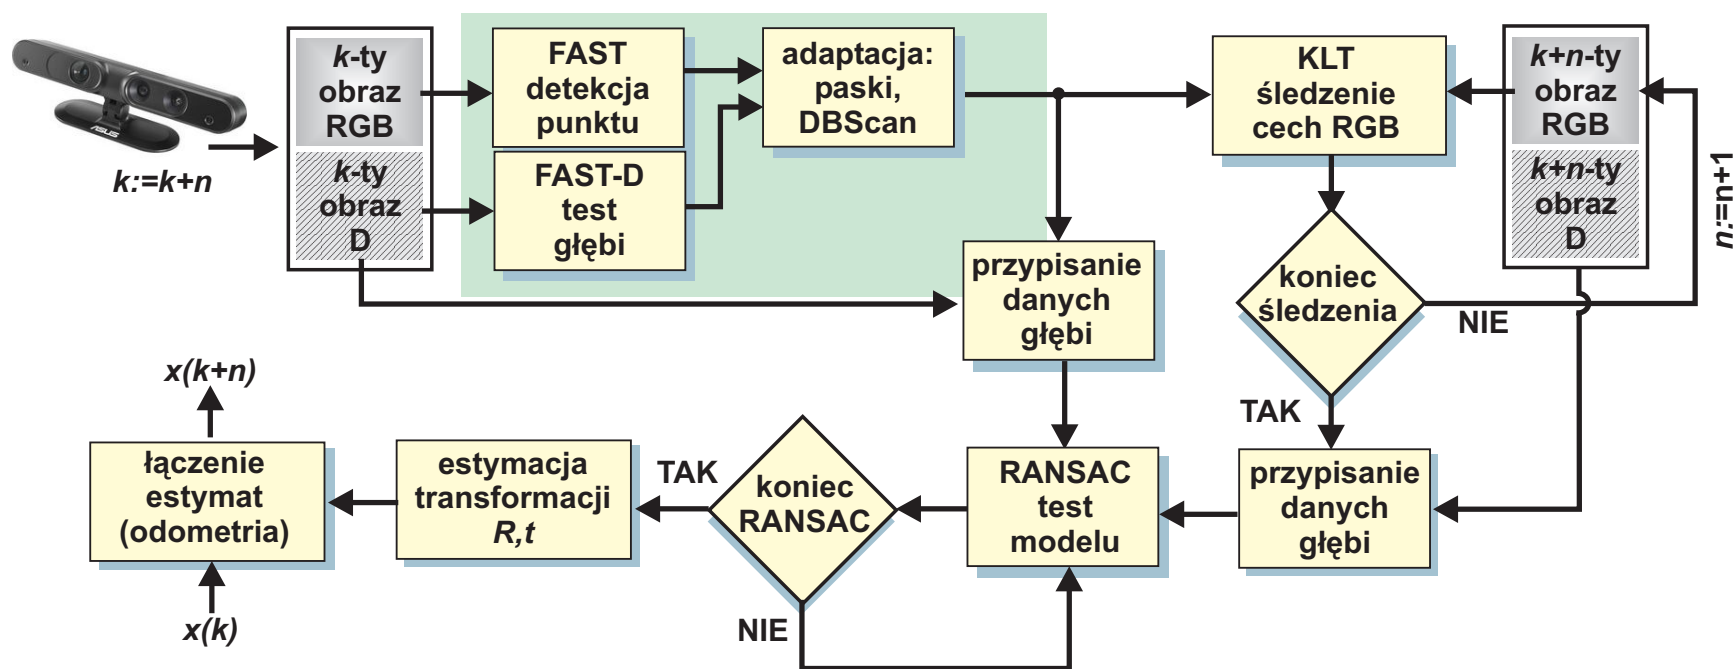
# Odometria wizyjna RGB-D

- Schemat blokowy algorytmu odometrii wizyjnej RGB-D



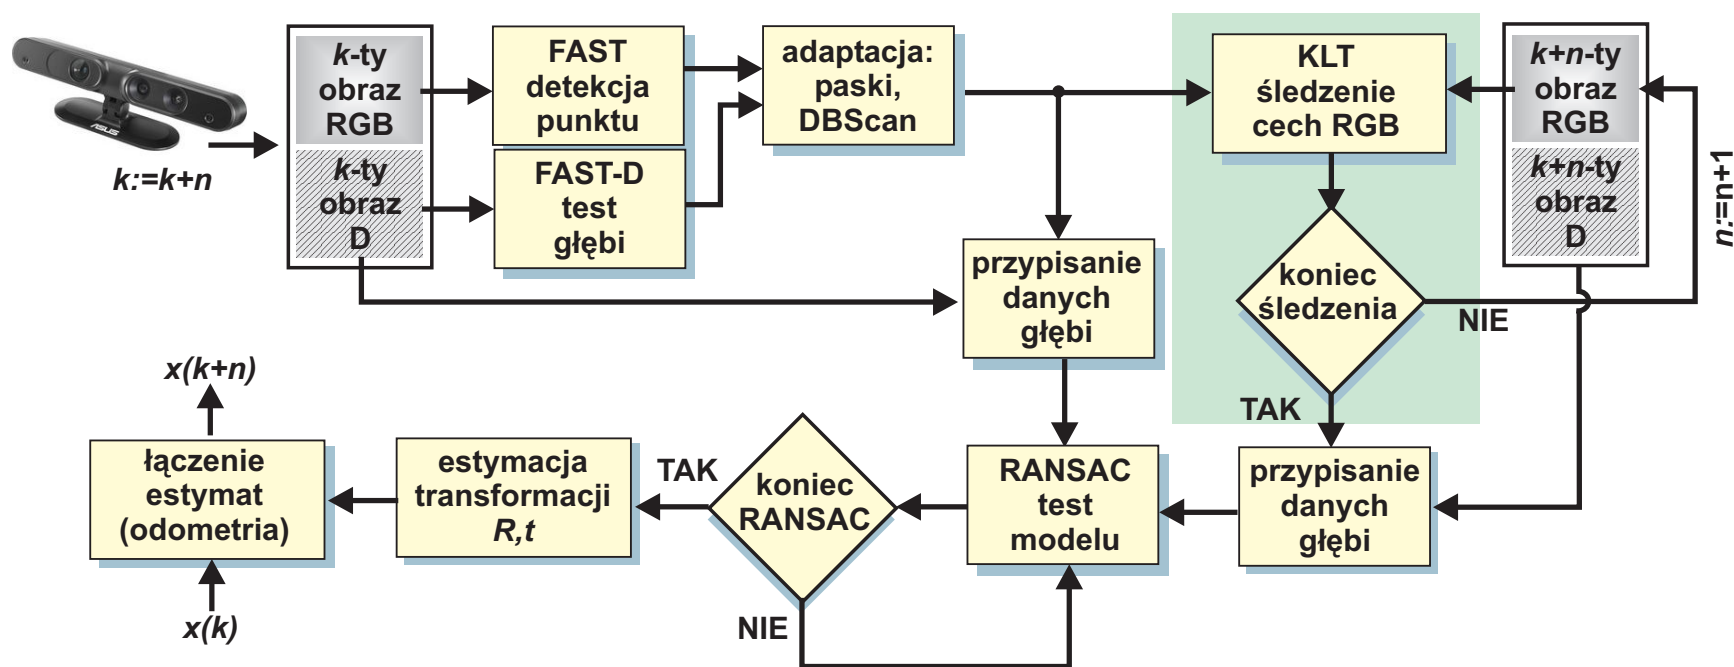
# Odometria wizyjna RGB-D

- Schemat blokowy algorytmu odometrii wizyjnej RGB-D



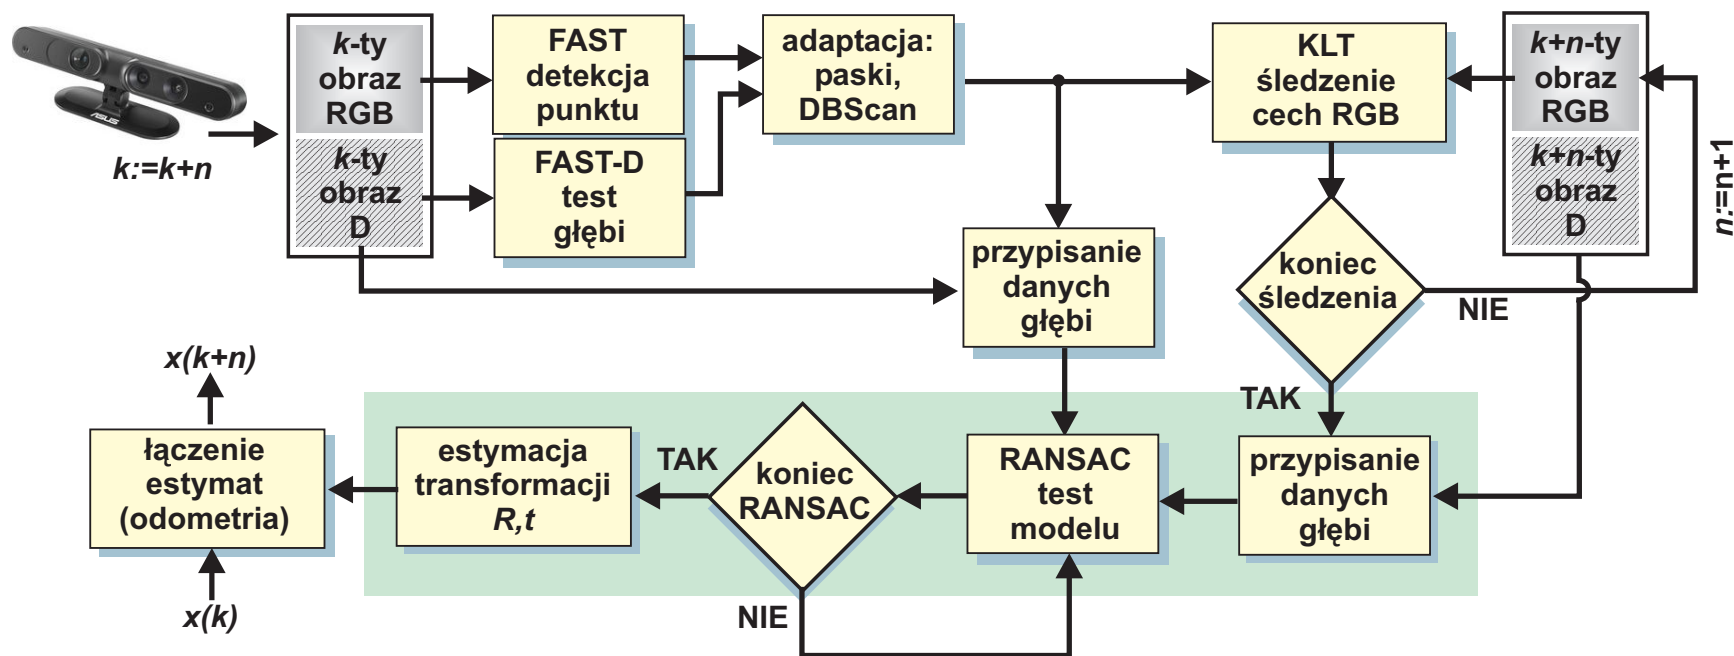
# Odometria wizyjna RGB-D

- Schemat blokowy algorytmu odometrii wizyjnej RGB-D



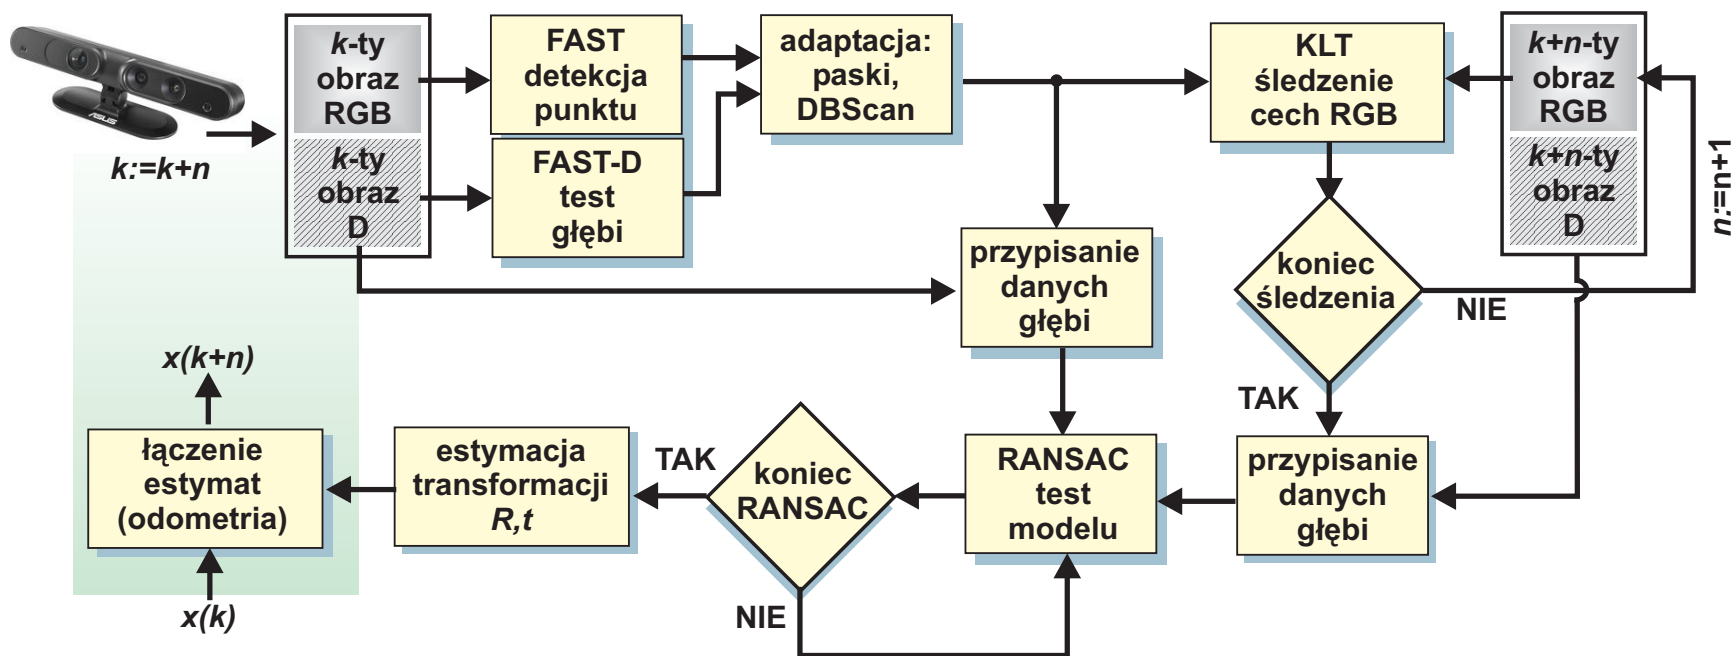
# Odometria wizyjna RGB-D

- Schemat blokowy algorytmu odometrii wizyjnej RGB-D




# Odometria wizyjna RGB-D

- Schemat blokowy algorytmu odometrii wizyjnej RGB-D



# Ekstrakcja cech


- Wyniki działania detektora FAST-D.






# Ekstrakcja cech

- Wyniki działania detektora FAST-D.




# Zarządzanie cechami

- Cechy wykryte za pomocą detektora FAST-D




# Zarządzanie cechami

- Cechy wykryte po podziale obrazu




# Zarządzanie cechami

- Cechy po grupowaniu algorytmem DBscan




# SLAM i optymalizacja

- Różne podejścia do rozwiązania problemu SLAM
- Sformułowanie bayesowskie (*Strasdat et al., 2012*)




# SLAM i optymalizacja

- Różne podejścia do rozwiązania problemu SLAM
- Filtracja (EKF, Particle Filter)




# SLAM i optymalizacja

- Różne podejścia do rozwiązania problemu SLAM
- Pose-based SLAM (optymalizacja)



# SLAM i optymalizacja

- Różne podejścia do rozwiązania problemu SLAM
- Sparse Bundle Adjustment (optymalizacja)






# PUT SLAM: koncepcja

- Typowy *pose-based* SLAM z optymalizacją:


$$\underset{\mathbf{p}}{\operatorname{argmin}} E = \sum_{ij} \tilde{\mathbf{e}}_{ij}^T \Omega_{ij} \tilde{\mathbf{e}}_{ij}$$



# PUT SLAM: koncepcja

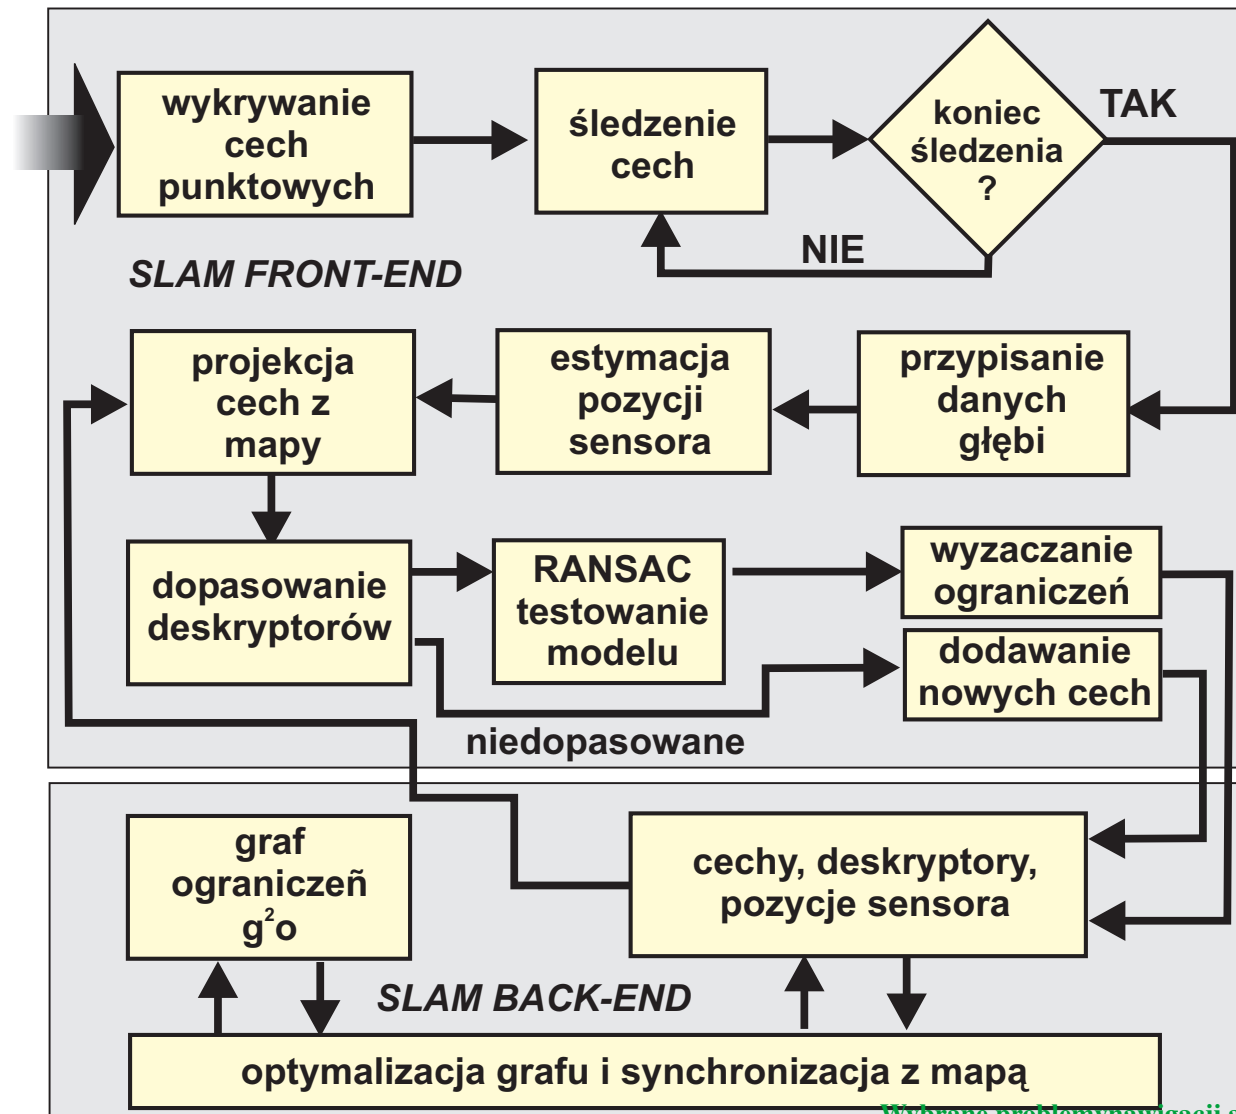
- PUT SLAM: podejście *bundle adjustment*:

$$\underset{\mathbf{p}}{\operatorname{argmin}} E = \sum_{i=1}^n \sum_{j=1}^m e(\mathbf{p}_i^c, \mathbf{p}_j^f, \mathbf{m}_{ij})^T \Omega_{ij} e(\mathbf{p}_i^c, \mathbf{p}_j^f, \mathbf{m}_{ij})$$



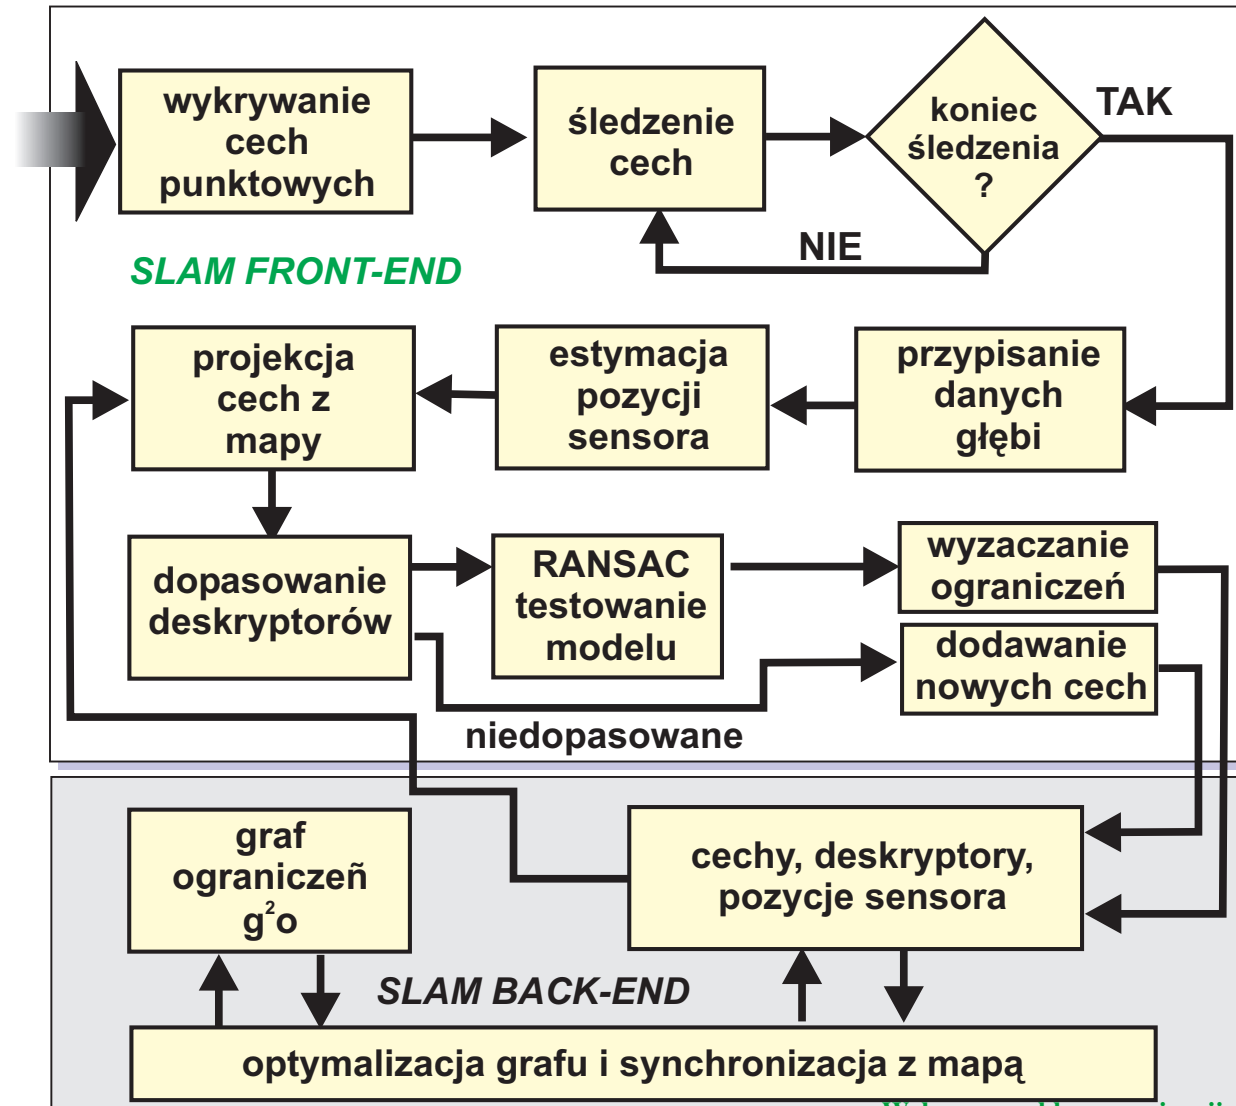
# Architektura PUT SLAM

- Schemat blokowy systemu PUT SLAM



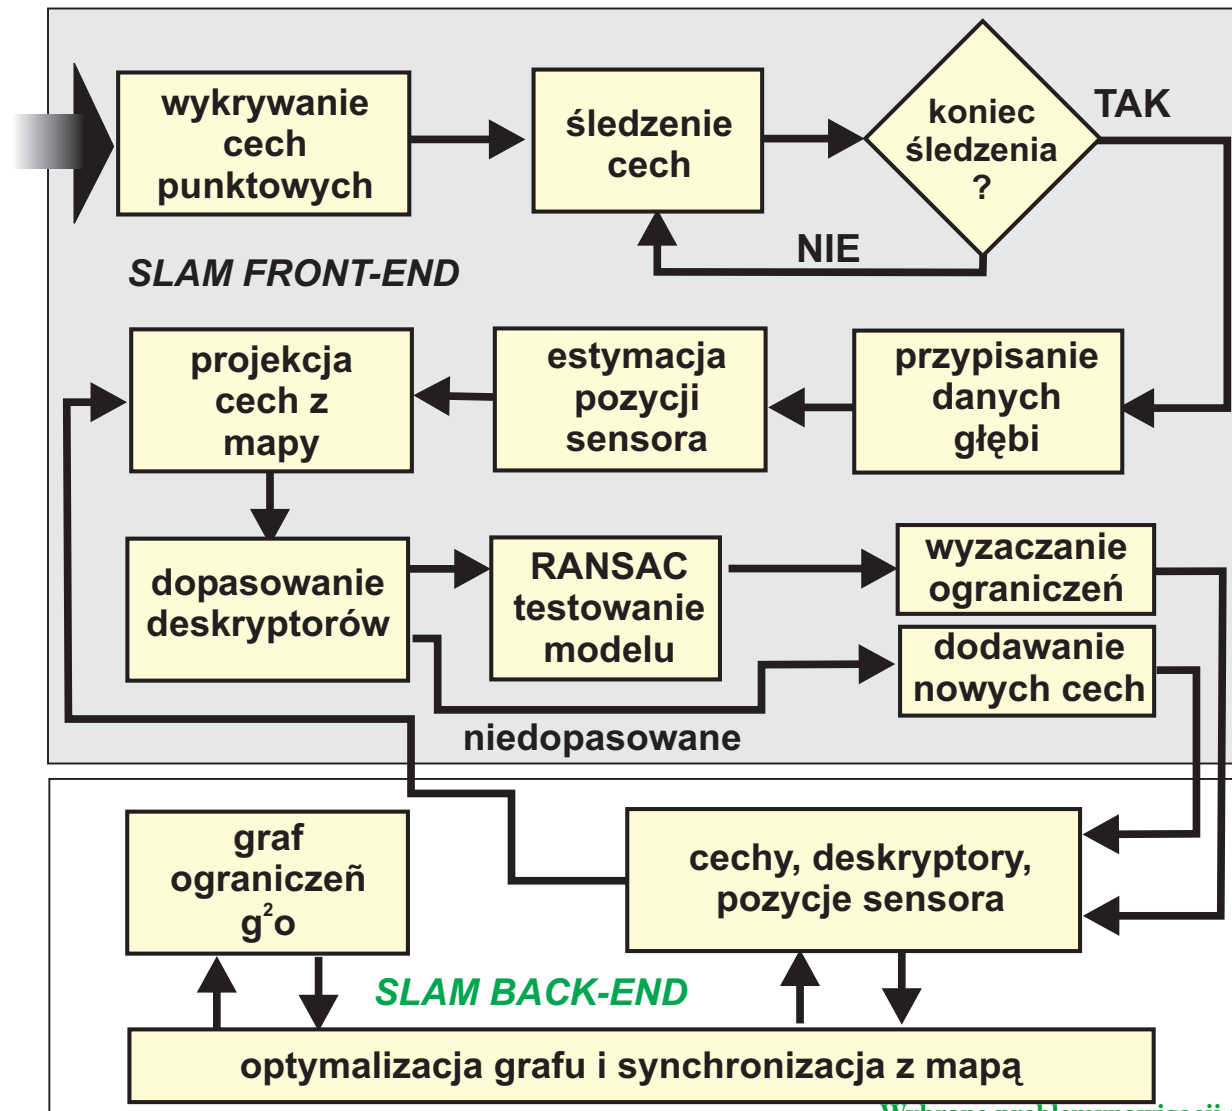
# Architektura PUT SLAM

- Schemat blokowy systemu PUT SLAM



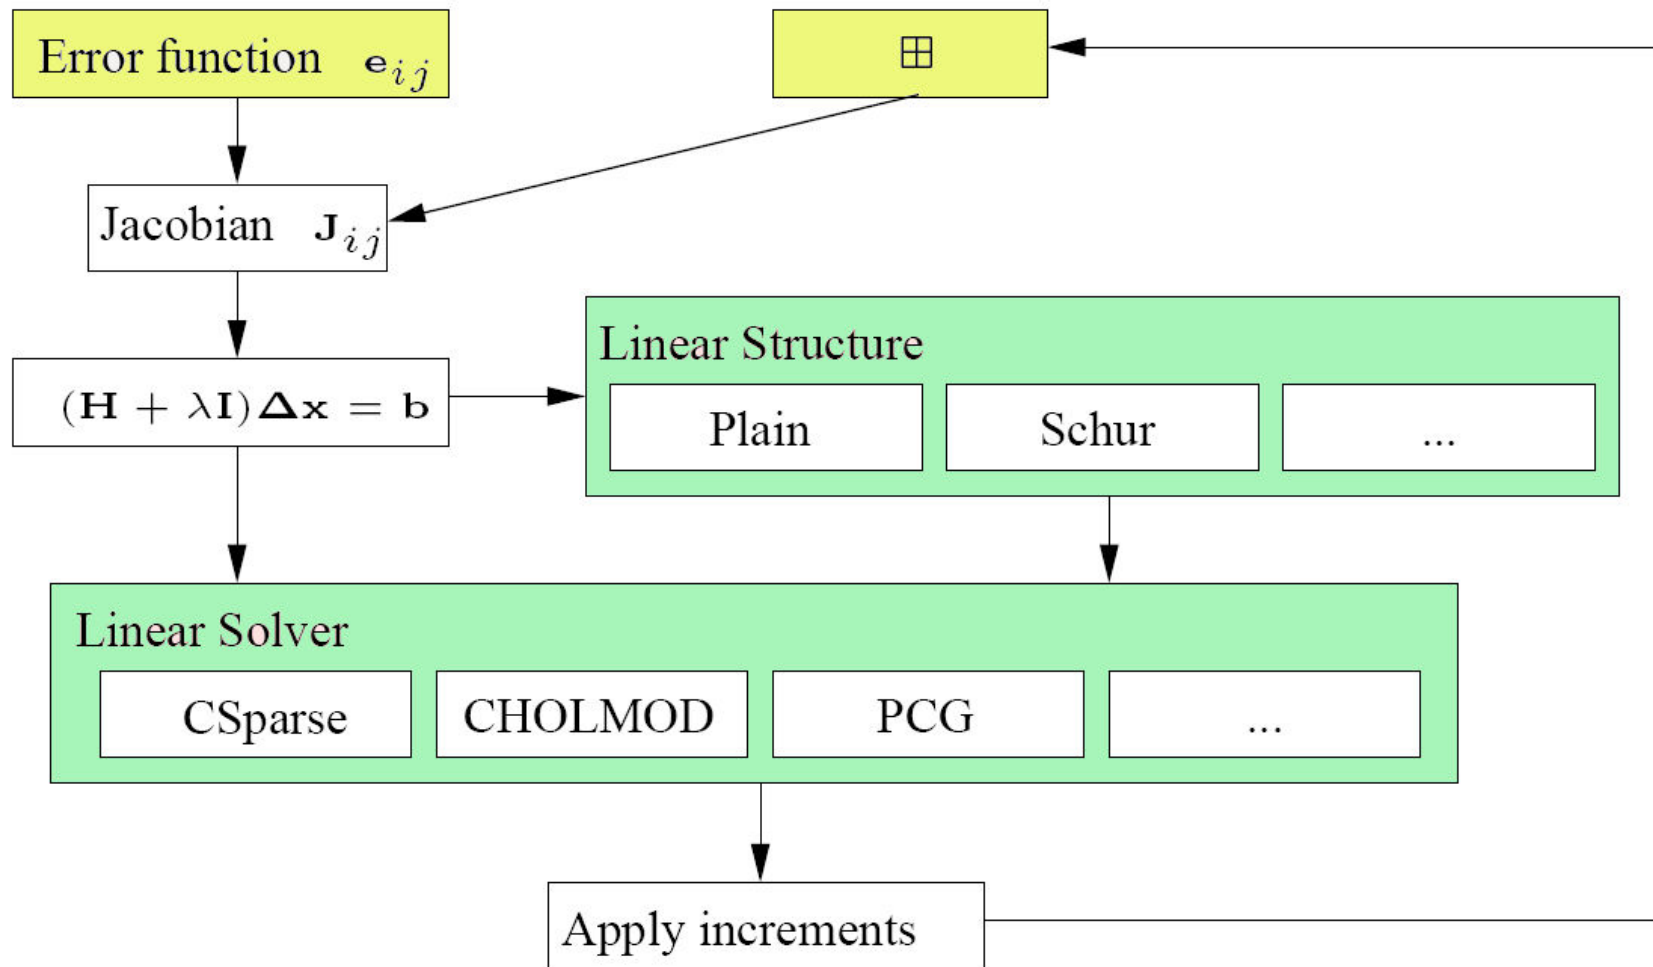
# Architektura PUT SLAM

- Schemat blokowy systemu PUT SLAM




# Optymalizacja: $g^2o$

- Struktura biblioteki  $g^2o$  (Kümmerle *et al.*, 2011)



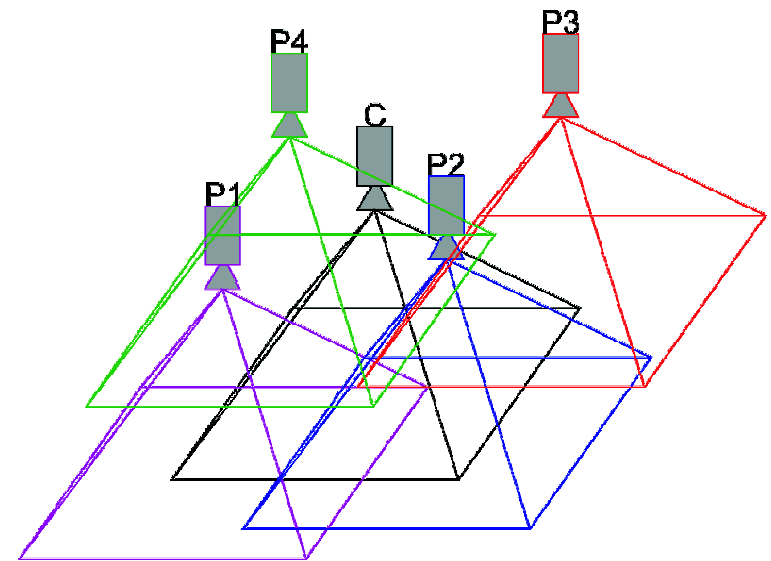

# Metodyka badań (1)

- TUM RGB-D Benchmark – przemieszczany ręcznie Kinect (*Sturm et al., 2012*).



# Metodyka badań (2)

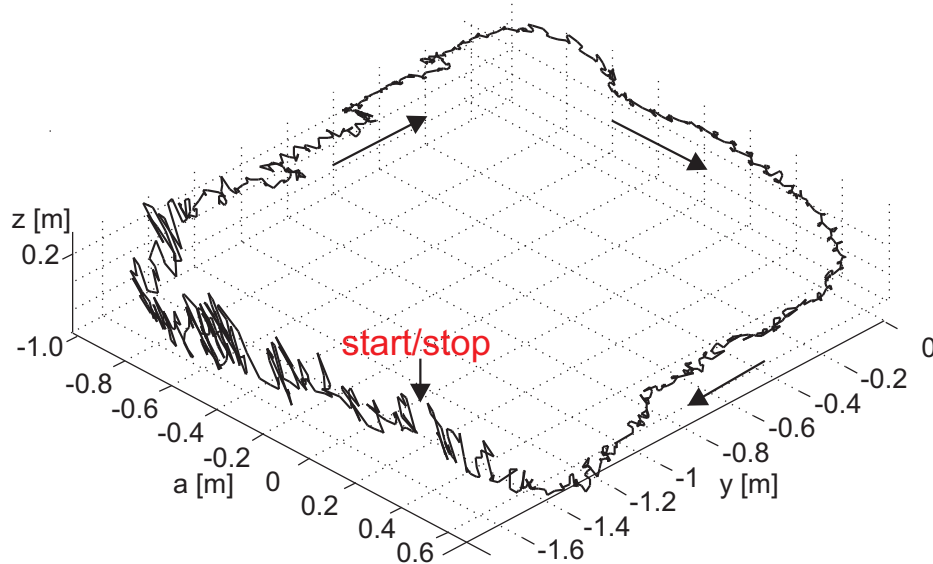
- Trajektorie odniesienia uzyskane za pomocą systemu kamer (Kraft *et al.*, 2016).
- Akwizycja danych RGB-D zsynchronizowana z pracą kamer (15Hz).






# Metodyka badań (3)

- Eksperymenty z robotem Messor II wykonane na makiecie terenu  $2 \times 2$  m (Belter *et al.*, 2016).
- Trajektorie testowe zbliżone kształtem do kwadratu.




# Wyniki badań (1)

- TUM RGB-D Benchmark  
fr3\_long\_office\_household
- ATE: PUT SLAM 0.02m, ORB-SLAM2 0.009m
- ATE: RGB-D SLAM v2 0.095m, CCNY 0.106m




# Wyniki badań (1)

- TUM RGB-D Benchmark  
fr3\_long\_office\_household
- ATE: PUT SLAM 0.02m, ORB-SLAM2 0.009m
- ATE: RGB-D SLAM v2 0.095m, CCNY 0.106m




# Wyniki badań (1)

- TUM RGB-D Benchmark  
fr3\_long\_office\_household
- ATE: PUT SLAM 0.02m, ORB-SLAM2 0.009m
- ATE: RGB-D SLAM v2 0.095m, CCNY 0.106m




# Wyniki badań (2)

- Robot kołowy, sekwencja putkk\_1
- ATE: PUT SLAM 0.104m, ORB-SLAM2 0.018m
- ATE: RGB-D SLAM v2 **FAIL**, CCNY 0.529m




# Wyniki badań (2)

- Robot kołowy, sekwencja putkk\_1
- ATE: PUT SLAM 0.104m, ORB-SLAM2 0.018m
- ATE: RGB-D SLAM v2 **FAIL**, CCNY 0.529m




# Wyniki badań (2)

- Robot kołowy, sekwencja putkk\_1
- ATE: PUT SLAM 0.104m, ORB-SLAM2 0.018m
- ATE: RGB-D SLAM v2 **FAIL**, CCNY 0.529m



# Wyniki badań (3)


- Robot Messor II, sekwencja `messor2_2`
- ATE: PUT SLAM 0.069m, ORB-SLAM2 **FAIL**
- ATE: RGB-D SLAM v2 0.158m, CCNY 0.307m





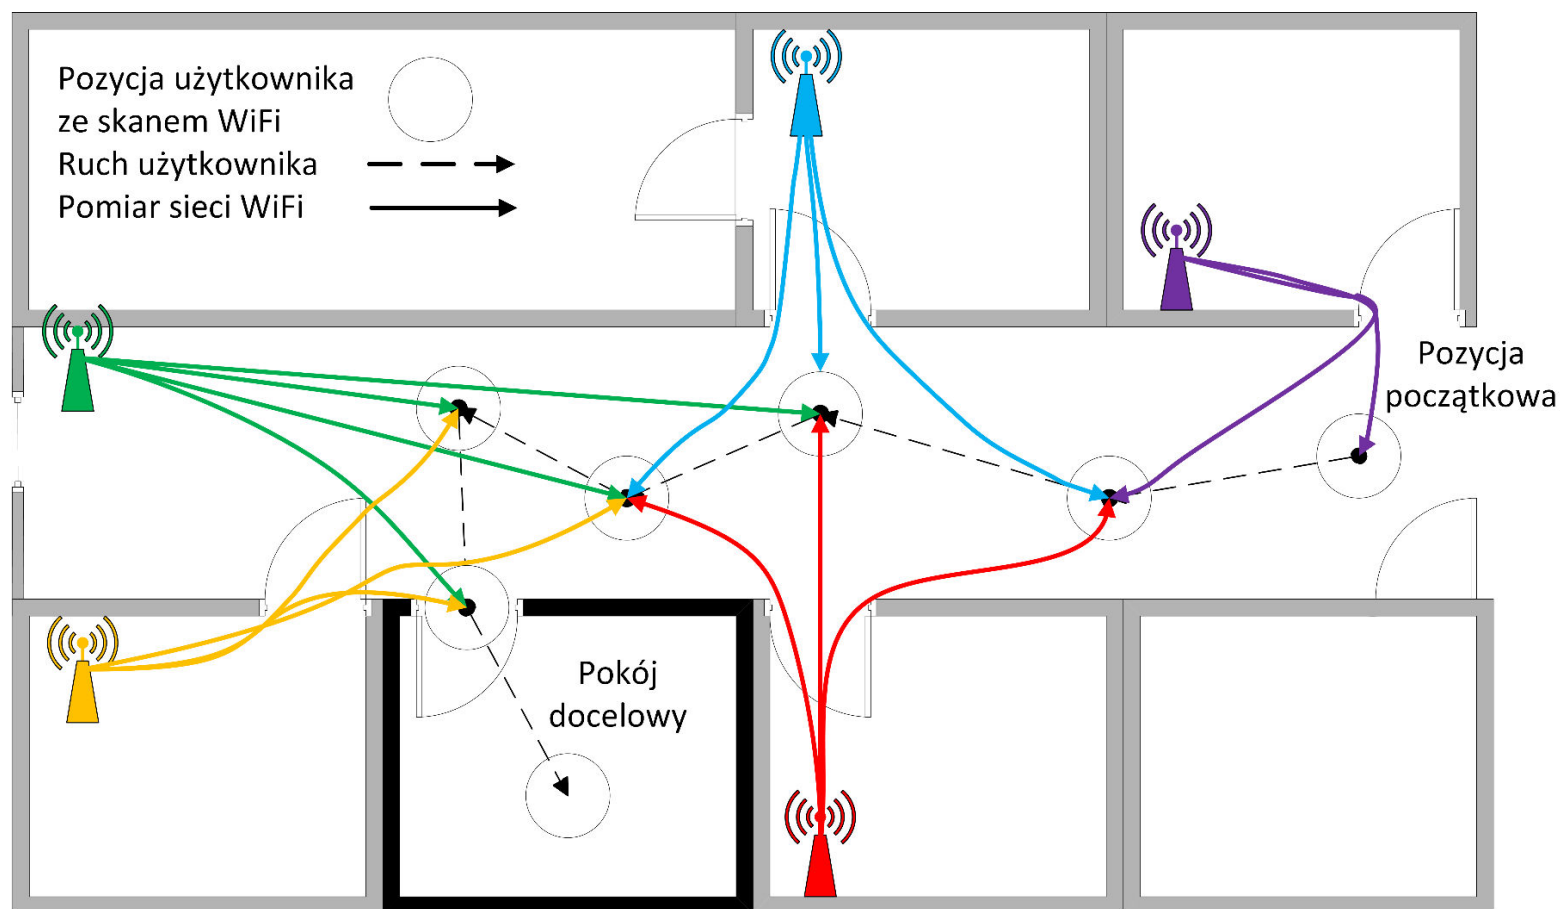
# Wyniki badań (3)

- Robot Messor II, sekwencja `messor2_2`
- ATE: PUT SLAM 0.069m, ORB-SLAM2 **FAIL**
- ATE: RGB-D SLAM v2 0.158m, CCNY 0.307m



# Lokalizacja WiFi (pose-based)

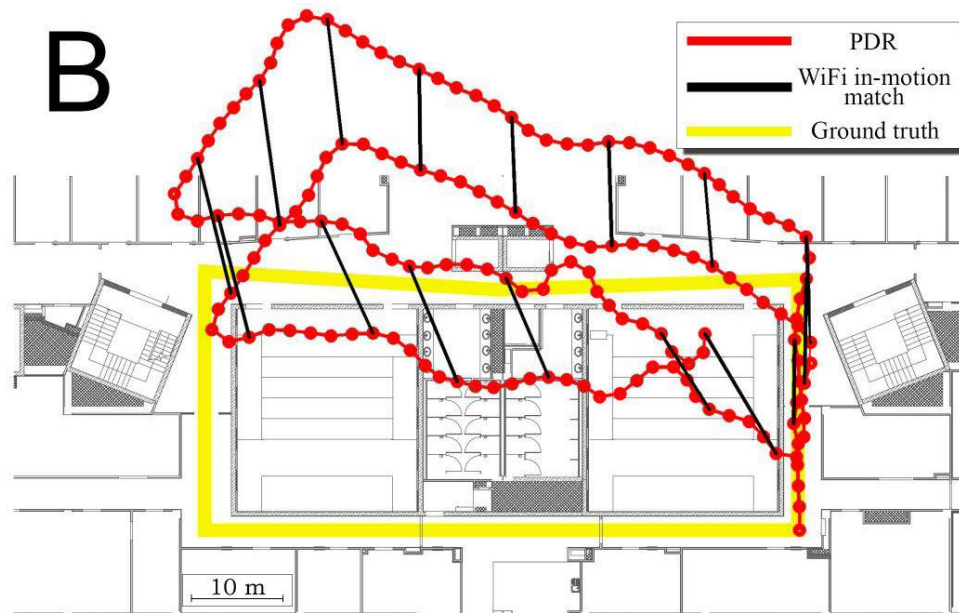
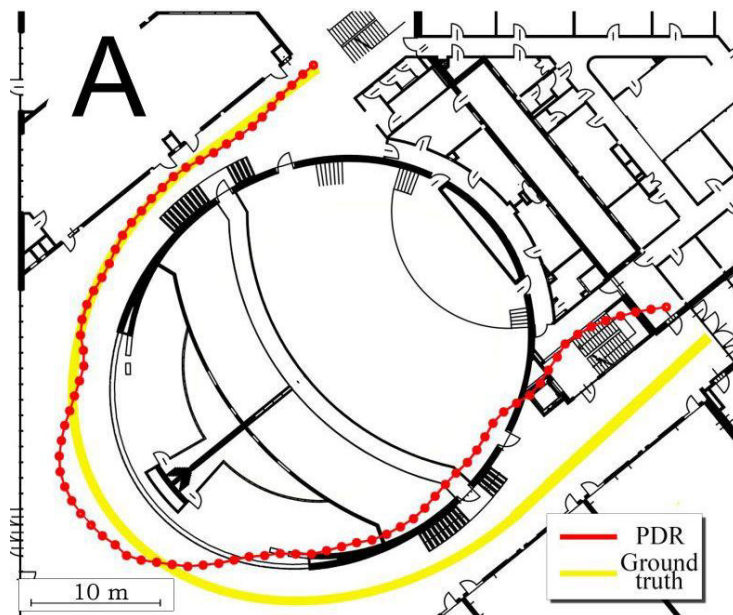
- Wykorzystanie sygnatur WiFi (fingerprints)
- Wystarczy znać pozycje wybranych AP WiFi



# Lokalizacja WiFi – wyniki

- Wykorzystanie tylko krokomierza oraz IMU

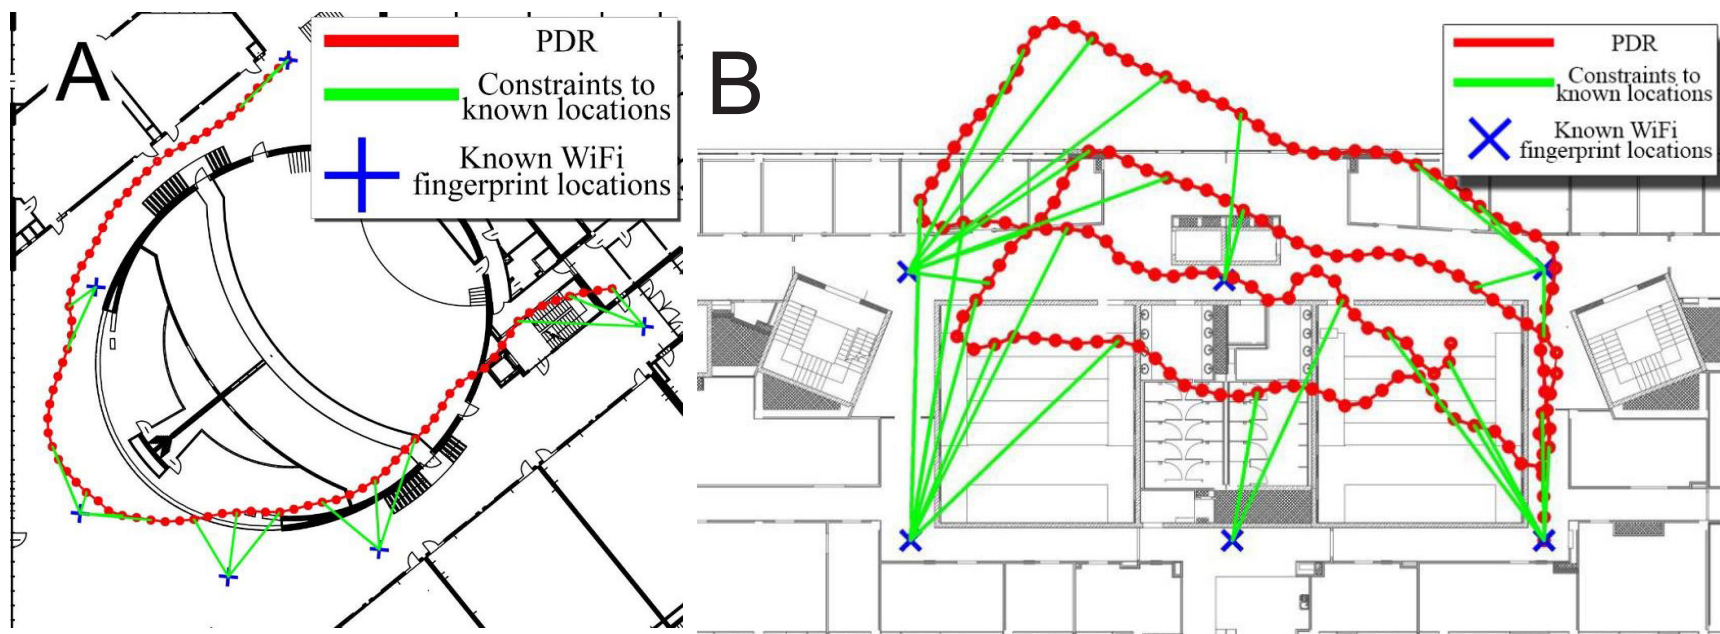
A – centrum wykładowe PP, B – centrum mechatroniki PP



# Lokalizacja WiFi – wyniki

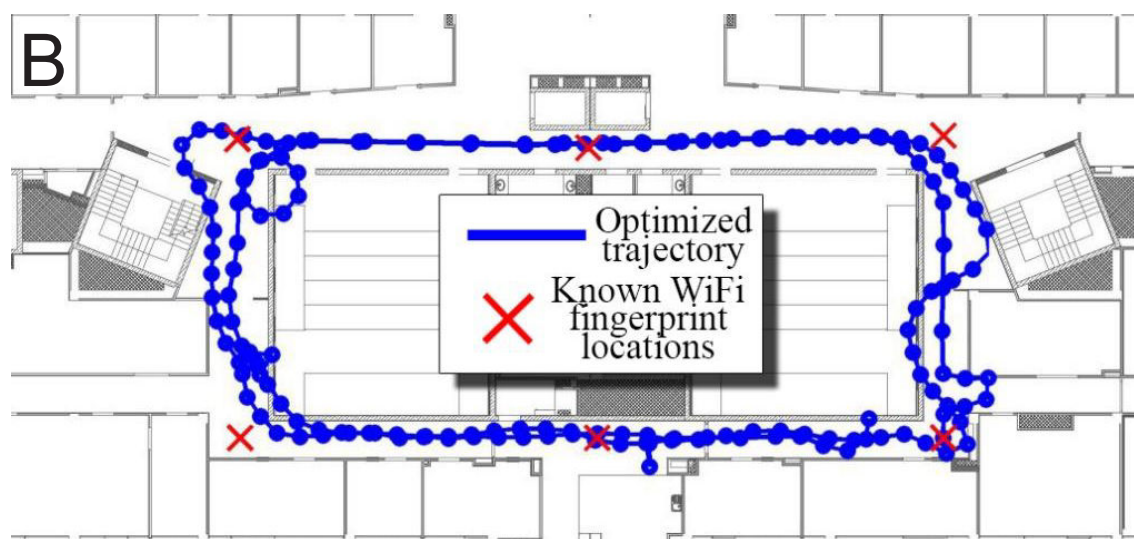
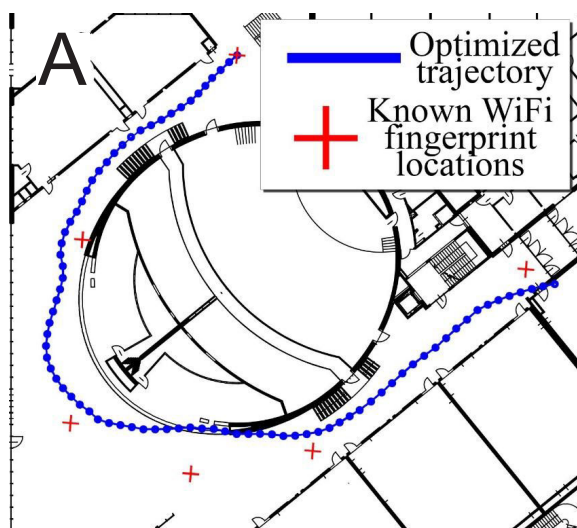
- Wprowadzenie informacji o wybranych AP

A – centrum wykładowe PP, B – centrum mechatroniki PP



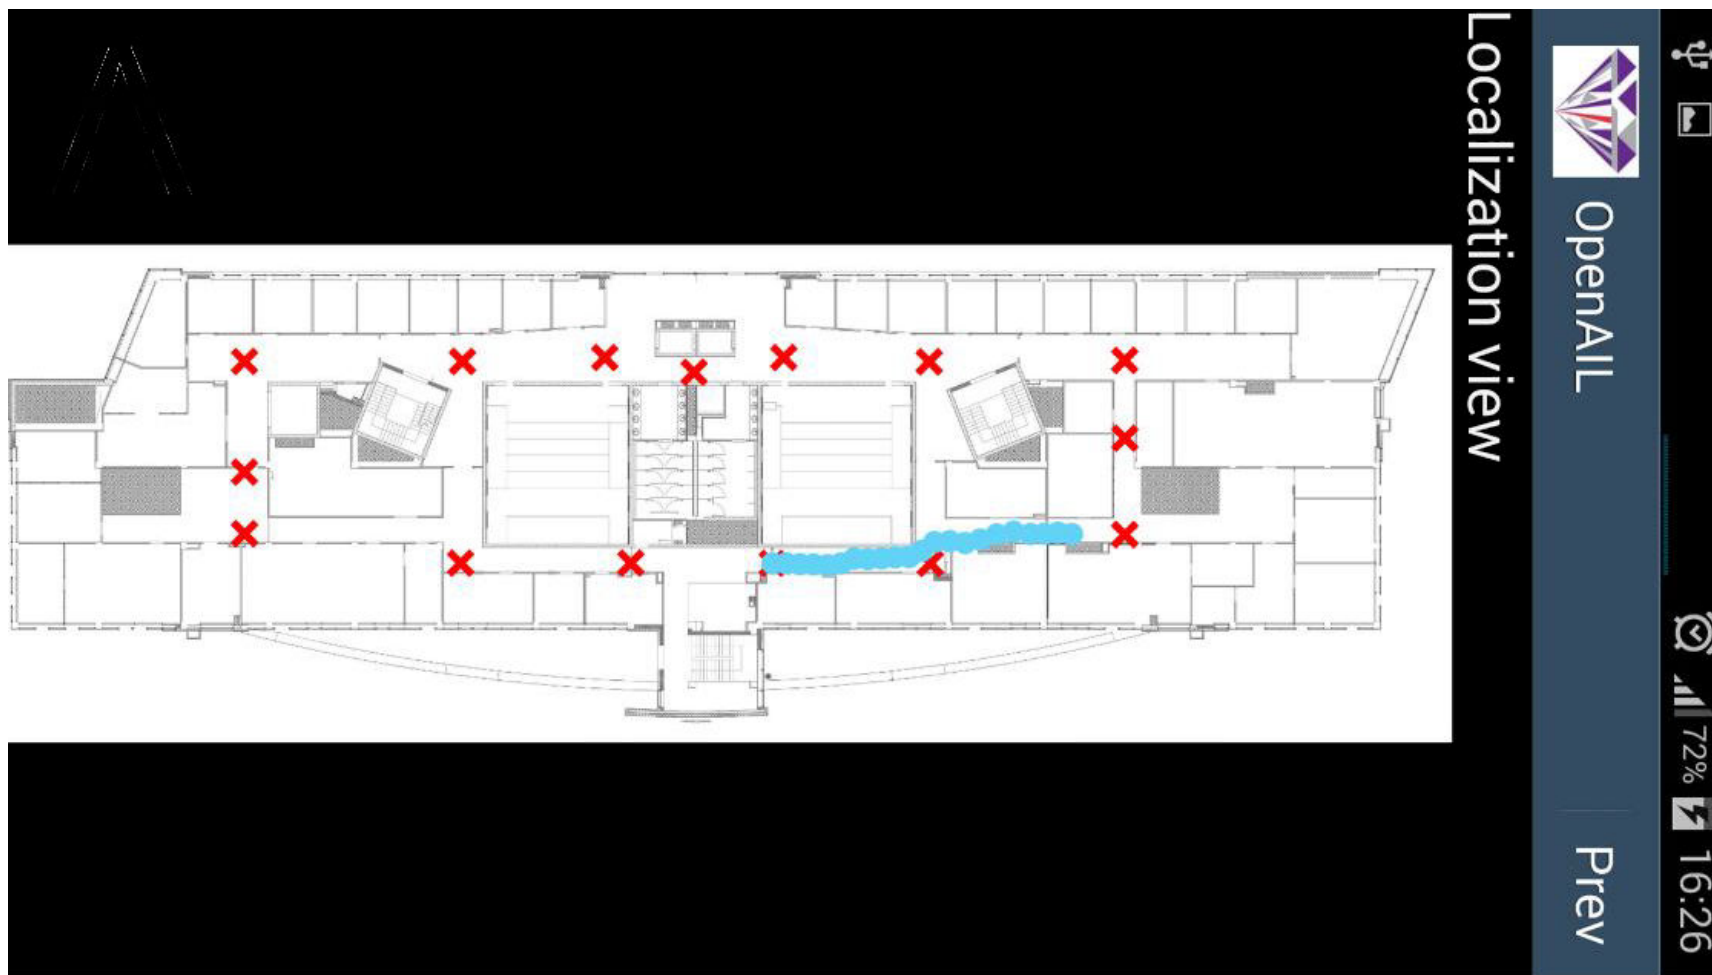
# Lokalizacja WiFi – wyniki

- Wyniki po optymalizacji grafu: krokومترz + IMU + WiFi A – centrum wykładowe PP, B – centrum mechatroniki PP



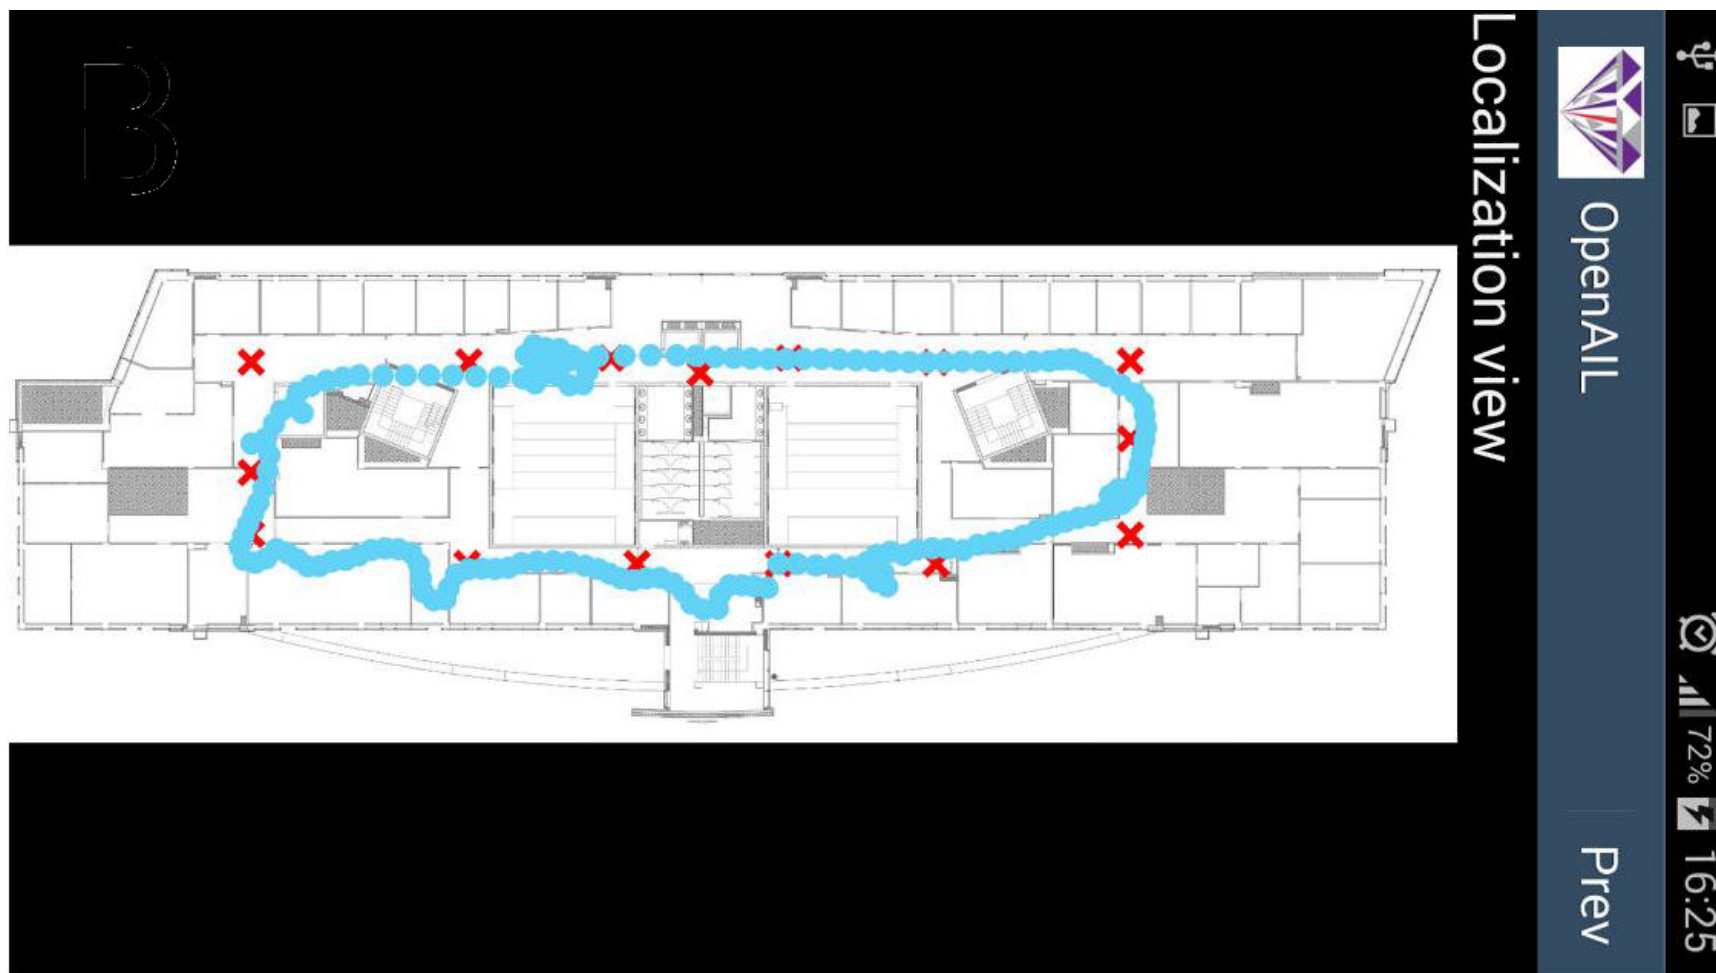
# Aplikacja: Android

- Działanie aplikacji lokalizacyjnej – Samsung Galaxy Note S3



# Aplikacja: Android

- Działanie aplikacji lokalizacyjnej – Samsung Galaxy Note S3




# Podsumowanie

- Architektury systemów SLAM uważane za reprezentatywne nie zawsze radzą sobie dobrze z danymi uzyskanymi przez roboty.
- PUT SLAM wykazał się skutecznością działania we wszystkich eksperymentach.
- Koncepcja SLAM opartej na optymalizacji jest bardzo uniwersalna.
- Współczesne metody optymalizacji umożliwiają działanie w czasie rzeczywistym.



# What next ?



# Zasoby

Kod *open-source* PUT SLAM dostępny na GitHub:

<https://github.com/LRMPUT/PUTSLAM/tree/release>


Strona WWW PUT SLAM:

<http://lrm.put.poznan.pl/putslam/>

# Laboratorium Robotów Mobilnych

*Zakład Automatyki i Robotyki*  
*Instytut Automatyki i Inżynierii Informatycznej*  
*Politechnika Poznańska*

<http://irm.put.poznan.pl>



# Zespół

- Pracownicy naukowi:
  - dr hab. inż. Piotr Skrzypczyński, prof. nadzw.
  - dr inż. Dominik Belter, adiunkt
  - dr inż. Krzysztof Walas, adiunkt
  - mgr inż. Michał Nowicki, asystent
  - mgr inż. Jan Wietrzykowski, asystent
- Doktoranci: pięć osób
- Współpraca z innymi grupami badawczymi w ramach Zakładu

# Tematyka badań (1)

- Autonomiczne roboty mobilne
  - autonomiczna nawigacja w pomieszczeniach
  - autonomiczna nawigacja *outdoor*
  - współpraca robotów i koordynacja działań
- Jednoczesna samolokalizacja i budowa mapy (SLAM)
  - 2D SLAM
  - 3D RGB-D SLAM
  - 3D visual odometry & visual SLAM

# Tematyka badań (2)

- Roboty kroczące
  - sterowanie chodem i planowanie ruchu
  - percepcja i samolokalizacja
- Roboty antropomorficzne
  - planowanie ruchu
  - wykorzystanie wzorców ruchu człowieka
- Nawigacja *indoor* dla urządzeń mobilnych (smartfony itp.)
  - nawigacja na dużych obszarach (cały budynek)
  - *GPS-denied environments*
  - wykorzystanie danych z wielu sensorów

# Projekty badawcze



- Narodowe Centrum Nauki
  1. OPUS
  2. ETIUDA
  3. 3 × PRELUDIUM
- Ministerstwo Nauki i Szkolnictwa Wyższego
  1. Projekty badawcze własne (przed rokiem 2011)
  2. “Diamentowy Grant”
  3. “Generacja Przyszłości”
- Narodowe Centrum Badań i Rozwoju
  1. LIDER

# Współpraca międzynarodowa




- University of Birmingham (UK)
- ETH Zürich (CH)
- FZI Karlsruhe (DE)
- University of Antwerp (BE)
- Czech Technical University in Prague (CZ)
- RMIT, Melbourne (AU)








# Roboty (1)





# Roboty (2)




# Roboty (3)



# Sensory (1)



# Sensory (2)



# Wybrane publikacje 2012–2016

1. P. Skrzypczyński, Laser Scan Matching for Self-Localization of a Walking Robot in Man-Made Environments, *Industrial Robot: An International Journal*, 39(3), 2012, 242–250.
2. D. Belter, P. Skrzypczyński, Precise Self-Localization of a Walking Robot on Rough Terrain Using Parallel Tracking and Mapping, *Industrial Robot: An International Journal*, 40(3), 2013, 229–237.
3. K. Walas, Terrain Classification and Negotiation with a Walking Robot, *Journal of Intelligent & Robotic Systems* 78(3), 2014, 401–423.
4. J. Gośliński, M. Nowicki, P. Skrzypczyński, Performance Comparison of EKF-Based Algorithms for Orientation Estimation on Android Platform, *IEEE Sensors Journal*, 15(7), 2015, 3781–3792.
5. M. Kraft, M. Nowicki, R. Penne, A. Schmidt, P. Skrzypczyński, Efficient RGB-D Data Processing for Feature-based Self-localization of Mobile Robots, *Int. Journal of Applied Mathematics and Computer Science*, 26(1), 2016, 63–79.
6. D. Belter, P. Labęcki, P. Skrzypczyński, Adaptive Motion Planning for Autonomous Rough Terrain Traversal with a Walking Robot, *Journal of Field Robotics*, 33(3), 2016, 337–370.

# Wybrane publikacje 2012–2016

7. D. Belter, P. Labęcki, P. Fankhauser, R. Siegwart, RGB-D Terrain Perception and Dense Mapping for Legged Robots, *Int. Journal of Applied Mathematics and Computer Science*, 26(1), 2016, 81–97.
8. M. Kraft, M. Nowicki, A. Schmidt, M. Fularz, P. Skrzypczyński, Toward Evaluation of Visual Navigation Algorithms on RGB-D Data from the First- and Second-Generation Kinect, *Machine Vision and Applications*, 2016.
9. J. Wietrzykowski, D. Belter, Boosting Support Vector Machines for RGB-D Based Terrain Classification, *Journal of Automation, Mobile Robotics and Intelligent Systems*, 8(3), 2014, 28–34.
10. J. Wietrzykowski, On the Representation of Planes for Efficient Graph-Based SLAM with High-Level Features, *Journal of Automation, Mobile Robotics and Intelligent Systems*, 10(3), 2016, 3–11.
11. D. Belter, M. Nowicki, P. Skrzypczyński, On the Performance of Pose-Based RGB-D Visual Navigation Systems, in: *Computer Vision – ACCV 2014*, LNCS 9004, Springer 2015, 407–423.
12. D. Belter, M. Nowicki, P. Skrzypczyński, Improving Accuracy of Feature-Based RGB-D SLAM by Modeling Spatial Uncertainty of Point Features, *Proc. IEEE Int. Conf. on Robotics & Automation*, Stockholm, 2016, 1279–1284.