

# Programowanie autonomicznych robotów

---

Przedmiot: Robotyka i Systemy Autonomiczne

dr inż. Mateusz Pomianek

ROS 2 · SLAM · Python/C++ · Gazebo · Nav2 · MoveIt

Architektura systemów i ROS 2

Percepcja — LiDAR, kamera, SLAM

Planowanie ścieżki i nawigacja

Sterowanie — PID, BT, RL

Bezpieczeństwo i standardy

# Plan Wykładu — 30 Slajdów

Sl. 1–3

Wprowadzenie — autonomia, architektury i ekosystem ROS 2

Sl. 6–7

ROS 2 — węzły, topiki, serwisy, akcje (Python/C++)

Sl. 10–11

Percepcja 3D — chmury punktów, PCL, YOLO dla robotów

Sl. 14–15

Planowanie ścieżki — A\*, RRT\*, Dijkstra, Nav2

Sl. 18–19

Movel2 2 — manipulatory, trajektorie, IK

Sl. 22–23

Systemy wbudowane — STM32, RTOS, komunikacja CAN/I<sup>2</sup>C

Sl. 26–27

Bezpieczeństwo i standardy — ISO 10218, ISO 26262

Sl. 30

Trendy — Embodied AI, Foundation Models, ROS 3

Sl. 4–5

Kinematyka — DH, forward/inverse kinematics

Sl. 8–9

Sensory robotów — LiDAR, stereo, IMU, enkodery

Sl. 12–13

SLAM — Simultaneous Localization and Mapping

Sl. 16–17

Sterowanie — PID, maszyny stanów, Behavior Trees

Sl. 20–21

Uczenie ze wzmocnieniem — PPO, SAC, Sim2Real

Sl. 24–25

Symulacja — Gazebo, Webots, NVIDIA Isaac Sim

Sl. 28–29

Studium przypadku — robot dostawczy i AV

# Czym jest robot autonomiczny? Definicja i poziomy autonomii

*"A robot is any automatically operated machine that replaces human effort, though it may not resemble human beings in appearance or perform functions in a humanlike manner." — IEEE Standard 610.3*

## Trzy filary autonomicznego robota

### Percepcja (Sensing)

Zbieranie danych o świecie: LiDAR, kamera, IMU, enkodery, dotyk. Kluczowe: jakość danych i kalibracja sensorów. Garbage in → garbage out.

### Przetwarzanie (Processing)

Interpretacja sensorów → model świata → decyzja. Pipeline: percepcja → lokalizacja → planowanie → sterowanie. Często w czasie rzeczywistym.

### Działanie (Actuation)

Silniki, serwomechanizmy, napędy, chwytaki. Pętla zwrotna: encoder → PID → PWM → silnik → enkoder. Dokładność ≈ pędnia napędowa.

## Poziomy autonomii (SAE J3016 + robotics)

L0

### Brak autonomii

Człowiek wykonuje wszystko. Teleoperacja. Pilot drona z joystickiem.

L1

### Wspomaganie

Robot asystuje w jednym wymiarze. Serwonapęd stabilizujący kamerę.

L2

### Częściowa

Robot kontroluje kilka osi, człowiek nadzoruje. Cobot assist.

L3

### Warunkowa

Robot autonomiczny w określonych warunkach. Warehouse AMR.

L4

### Wysoka

Pełna autonomia w zdefiniowanym obszarze ODD. Delivery robot.

L5

### Pełna autonomia

Dowolne warunki, dowolne środowisko. Naukowy cel—nie osiągnięty.

# Kinematyka robotów: Denavit-Hartenberg i Transformacje

## Macierze transformacji i notacja DH

```
Python
# Parametry DH: a, d, alpha, theta
# a      = długość czionu (X-axis)
# d      = przesunięcie (Z-axis)
# alpha  = skręt osi Z (X-axis)
# theta  = kąt obrotu (Z-axis)
import numpy as np

def dh_matrix(a, d, alpha, theta):
    ct, st = np.cos(theta), np.sin(theta)
    ca, sa = np.cos(alpha), np.sin(alpha)
    return np.array([
        [ct, -st*ca, st*sa, a*ct],
        [st, ct*ca, -ct*sa, a*st],
        [0, sa, ca, d],
        [0, 0, 0, 1]
    ])

# Forward kinematics: T_0_n = T01 @ T12 @ ... @ T(n-1)n
def forward_kinematics(dh_params, q):
    T = np.eye(4)
    for i, (a, d, alpha) in enumerate(dh_params):
        T = T @ dh_matrix(a, d, alpha, q[i])
    return T # pozycja i orientacja end-effector
```

### Przestrzeń stawów vs. przestrzeń kartezjańska

$q \in \mathbb{R}^n$  (kąty/przemieszczenia stawów)  $\leftrightarrow x \in SE(3)$  (poza+orientacja). FK:  $q \rightarrow x$  prosta. IK:  $x \rightarrow q$  wieloznaczna lub niemożliwa.

### Osobliwości

Konfiguracje gdy Jacobian  $J$  traci rząd  $\rightarrow$  robot traci DOF. Np. wyciągnięte ramię. Wykrywanie:  $\det(J \cdot J^T) < \epsilon \rightarrow$  alarm.

Kinematyka opisuje ruch robota geometrycznie, bez rozważania sił. Parametry DH to standard opisu łańcucha kinematycznego.

## metody kinematyki odwrotnej (IK)

### Analityczna (closed-form)

Dokładna, deterministyczna. Możliwa tylko dla robotów  $\leq 6$ -DOF z uproszczonymi geometriami (np. PUMA 560). Wzory algebraiczne.

### Jacobian Inverse / DLS

$J^+ = J^T(JJ^T)^{-1}$ . Numeryczna iteracja  $\Delta q = J^+ \cdot \Delta x$ . DLS (Damped Least Squares) — odporny na singularności.

### FABRIK

Forward And Backward Reaching Inverse Kinematics. Iteracyjny, szybki, naturalnie unika singularności. Standard w animacji i cobotach.

### Optymalizacyjna (NLP)

IK jako minimalizacja  $\|FK(q) - x_{des}\|^2$ . Dodatkowe więzy: joint limits, kolizje, min torque. Używana w MoveIt 2 (TRAC-IK, KDL).

💡 IK analityczna jest szybsza 100x od numerycznej, ale MoveIt 2 domyślnie używa KDL (numerycznej). Dla cobotów real-time  $\rightarrow$  TRAC-IK lub analityczna dedykowana.

# Kinematyka robotów mobilnych: model i odometria

## Napęd różnicowy (differential drive)

```
Python
# Kinematyka napędu różnicowego
# v_L, v_R – prędkości lewego/prawego koła [m/s]
# L = rozstaw kół, R = promień koła

class DiffDriveKinematics:
    def __init__(self, wheel_radius, wheel_base):
        self.R = wheel_radius # promień koła [m]
        self.L = wheel_base # rozstaw kół [m]

    def forward(self, w_L, w_R):
        """omega [rad/s] → (v, omega_robot)"""
        v_L = w_L * self.R
        v_R = w_R * self.R
        v = (v_R + v_L) / 2.0 # prędkość liniowa
        w = (v_R - v_L) / self.L # prędkość kątowa
        return v, w

    def odometry(self, x, y, theta, v, w, dt):
        """Całkowanie pozycji po czasie dt"""
        theta_new = theta + w * dt
        x_new = x + v * np.cos(theta) * dt
        y_new = y + v * np.sin(theta) * dt
        return x_new, y_new, theta_new
```

### Błędy odometrii

Poślizg kół, nierówności terenu, niedokładność enkoderów. Błąd akumuluje się  $O(\sqrt{n})$ . Korekcja: fuzja z LiDAR/IMU (EKF) lub korekcja pętla.

### Holonomiczne vs. nieholonomiczne

Różnicowe i Ackermann: nieholonomiczne — nie mogą jechać bokiem.  
Mecanum/omnidirectional: holonomiczne — pełna swoboda w płaszczyźnie.

Roboty mobilne różnią się od manipulatorów. Nie mają sztywnego połączenia z bazą. Model kinematyczny + odometria = podstawa nawigacji.

## Typy kinematyk mobilnych

### Differential Drive

2 napędowe koła + 1–2 castery. Proste sterowanie, tanie. Turtlebot, Roomba.  $R_1 \equiv$ prosto,  $R_2 \equiv$ obrót w miejscu.

### Ackermann (auto)

Przednie koła skrętne (jak auto). Minimalny promień skrętu. Lidar-based AGV, samochody autonomiczne.

### Mecanum / Omni

Rollkowe koła  $45^\circ$ . Pełny ruch w płaszczyźnie XY + obrót. Wysokie koszty, wrażliwe na podłoże. Magazyny KUKA.

### Tracked (gąsienice)

Wysokie tarcie i stabilność. Terenowe. Brak poślizgu. Stosowany w robotach ratowniczych i militarnych.

### Legged (nózkowy)

Spot (Boston Dynamics): 4 nogi, MPC+RL. Niezwykła lokomocja. Trudne sterowanie — aktywny obszar badań.

# ROS 2: Robot Operating System 2, Architektura

ROS 2 to middleware dla robotów. Nie system operacyjny, lecz zbiór narzędzi, bibliotek i konwencji opartych o DDS (Data Distribution Service).

## Aplikacja (węzły)

`rclpy / rclcpp` · lifecycle nodes · composable nodes · executor · callback groups



## Middleware kliencka (rmw)

`rmw_fastrtps_cpp` · `rmw_cyclonedds` · `rmw_connextdds` – wymienne przez env var



## DDS / RTPS Transport

Fast-DDS (domyślny) · CycloneDDS · RTI Connext · QoS: reliability/durability/history



## Sieć / OS Layer

UDP multicast (local) / TCP unicast (remote) · Linux / macOS / Windows · POSIX realtime



## Narzędzia

`colcon build` · `ros2 topic/service/action` · `rviz2` · `rqt` · `ros2bag` · `foxcglove studio`

🔄 ROS 2 vs ROS 1: brak Master node (discovery rozproszone przez DDS) · QoS reliability · nowe typy: Actions (preemptable) · native Windows/Mac · lifecycle nodes · Executors (multi-thread) · security (SROS 2).

# ROS 2: Publisher, Subscriber, Serwis i Akcja (Python/C++)

Komunikacja w ROS 2: Topic (pub/sub, 1:N) · Service (req/resp, synchroniczny) · Action (długie zadanie z feedbackiem, cancelable).

## Publisher & Subscriber (Python)

```
import rclpy
from rclpy.node import Node
from std_msgs.msg import Float32
from geometry_msgs.msg import Twist

class VelocityPublisher(Node):
    def __init__(self):
        super().__init__("vel_pub")
        self.pub = self.create_publisher(
            Twist, "/cmd_vel", 10)
        # QoS depth=10 (ostatnie 10 wiadomości)
        self.timer = self.create_timer(
            0.1, self.publish_vel) # 10 Hz

    def publish_vel(self):
        msg = Twist()
        msg.linear.x = 0.3 # [m/s]
        msg.angular.z = 0.1 # [rad/s]
        self.pub.publish(msg)
        self.get_logger().info(
            f"v={msg.linear.x:.2f}")

def main():
    rclpy.init()
    rclpy.spin(VelocityPublisher())
    rclpy.shutdown()
```

Python

### QoS Profile

RELIABLE+VOLATILE (domyślny) · BEST\_EFFORT dla sensora ·  
TRANSIENT\_LOCAL+RELIABLE dla /map. Mismatch → brak połączenia.

## Action Server (nawigacja do celu)

```
from nav2_msgs.action import NavigateToPose
from rclpy.action import ActionClient
import rclpy
from rclpy.node import Node

class NavClient(Node):
    def __init__(self):
        super().__init__("nav_client")
        self._client = ActionClient(
            self, NavigateToPose,
            "navigate_to_pose")

    def send_goal(self, x, y, yaw=0.0):
        goal = NavigateToPose.Goal()
        goal.pose.header.frame_id = "map"
        goal.pose.pose.position.x = x
        goal.pose.pose.position.y = y
        self._client.wait_for_server()
        future = self._client.send_goal_async(
            goal,
            feedback_callback=self.feedback_cb)
        future.add_done_callback(self.goal_response)

    def feedback_cb(self, feedback):
        dist = feedback.feedback.distance_remaining
        self.get_logger().info(
            f"Dystans: {dist:.2f} m")
```

Python

### ros2 launch

Startuj wiele węzłów: LaunchDescription + Node(). Grupy log,  
remapowania, parametry z YAML, composable containers.



Używaj lifecycle nodes dla krytycznych węzłów — gwarantuje poprawną inicjalizację i clean-up. Nav2 używa lifecycle zarządzanego przez lifecycle\_manager.

# Sensory robotów: LiDAR, Kamera, IMU i Enkodery

Wybór sensorów determinuje możliwości i koszty robota. Nie istnieje jeden sensor do wszystkiego — fuzja multimodalna jest konieczna.

## LiDAR 3D (VLP-16/Ouster OS1)

Time-of-flight: laser 905/1550nm, pomiar czasu lotu. Zasięg 100m, dokładność  $\pm 2\text{cm}$ . 16–128 linii skanujących. Chmura 700k pkt/s. Słabe: deszcz, mgła, lustrzane powierzchnie.

## Kamera stereo (ZED 2/RealSense)

Triangulacja: 2 kamery  $\rightarrow$  mapa głębokości RGB-D. ZED 2: 20m depth, 120 FPS, SDK z VO. Intel D435: 10m, 90 FPS, VGA depth. IMU wbudowany.

## Enkodery (absolutne/inkrementalne)

Inkrementalny: impulsy na obrót. Absolutny: unikalna pozycja bez referencji (Grey code). AMT102: 8192 CPR, 7\$. Kluczowe dla odometrii i PID.

## LiDAR 2D (RPLIDAR/Hokuyo)

Skanowanie 360° w jednej płaszczyźnie. Zasięg 12–25m, 0.33° rozdzielczość. Tani (RPLIDAR A3: 400\$). Podstawa SLAM 2D — Turtlebot, AMR magazynowy.

## IMU (VN-100, ICM-42688)

Accelerometr + żyroskop + (mag). 500–8000 Hz. Niezbędny dla EKF. VN-100: przemysłowy, EKF on-chip. Błąd integracji drift  $\sim 0.1^\circ/\text{s}$   $\rightarrow$  potrzebna fuzja.

## Inne: ToF, sonar, dotyk, GPS

HC-SR04 ultrasonic: 2–400cm,  $\pm 3\text{mm}$ . ToF (VL53L5CX): macierz 8x8. GPS RTK:  $\pm 2\text{cm}$  (outdoor). Czujniki siły/momentu: FT300 (Robotiq) do cobot compliance.

# Percepcja 3D: chmury punktów, PCL i PointNet

Chmura punktów to zbiór  $P = \{(x,y,z,i)_n\}$  — nieuporządkowany, setek tysięcy punktów per ramka. PCL (Point Cloud Library) to standard.

## PCL pipeline — filtrowanie i segmentacja

```
#include <pcl/point_cloud.h>
#include <pcl/filters/voxel_grid.h>
#include <pcl/segmentation/sac_segmentation.h>
#include <pcl/filters/extract_indices.h>

// Voxel grid downsampling (100k→5k pkt)
pcl::VoxelGrid<pcl::PointXYZ> vg;
vg.setInputCloud(cloud_raw);
vg.setLeafSize(0.05f, 0.05f, 0.05f); // 5cm voxel
vg.filter(*cloud_filtered);

// RANSAC plane segmentation (usuwanie podłogi)
pcl::SACSegmentation<pcl::PointXYZ> seg;
seg.setModelType(pcl::SACMODEL_PLANE);
seg.setMethodType(pcl::SAC_RANSAC);
seg.setDistanceThreshold(0.02); // 2cm
seg.setInputCloud(cloud_filtered);
pcl::ModelCoefficients::Ptr coeff(
    new pcl::ModelCoefficients);
pcl::PointIndices::Ptr inliers(
    new pcl::PointIndices);
seg.segment(*inliers, *coeff);
// coeff->values = [a,b,c,d] (równanie ax+by+cz+d=0)
```

## Sieci neuronowe dla chmur punktów

### PointNet (Qi et al., 2017)

Pierwsza sieć bezpośrednio na  $\{(x,y,z)\}$ : MLP per point → max pooling → global descriptor. Permutation invariant. 89.2% mAP ModelNet40. Podstawa wszystkich następných.

### PointNet++ (2017)

Hierarchiczne próbkowanie: farthest point sampling → local region → mini-PointNet. Lepšie na gęstych chmurach. Używany w autonomicznych samochodach.

### VoxelNet / PointPillars (2018)

Voxelizacja → 3D CNN. PointPillars: voxelę w kolumny 2D → 2D CNN → SSD detection head. 62 FPS na GPU. Waymo i Tesla używają podobnych architektur.

### Open3D i ROS 2 pointcloud2

sensor\_msgs/PointCloud2 w ROS 2. Open3D Python API: o3d.geometry.PointCloud → visualize, ICP registration, DBSCAN clustering. Interoperuje z NumPy.



Kalibruj LiDAR i kamerę wspólnie używając szachownicy 3D (ros2\_camera\_lidar\_calibration). Bez kalibracji fuzja sensorów da błędne wyniki projekcji.

# Computer Vision dla robotów: detekcja, segmentacja, głębokość

## YOLO dla robotów: detekcja w czasie rzeczywistym

```
from ultralytics import YOLO
import rclpy
from sensor_msgs.msg import Image
from cv_bridge import CvBridge

class YOLODetector(Node):
    def __init__(self):
        super().__init__("yolo_detector")
        self.model = YOLO("yolov8n.pt")
        # Dla robotyki: yolov8n < 3ms na Jetson
        self.bridge = CvBridge()
        self.sub = self.create_subscription(
            Image, "/camera/image_raw",
            self.image_cb, 10)

    def image_cb(self, msg):
        img = self.bridge.imgmsg_to_cv2(msg)
        results = self.model(img, conf=0.5)
        for box in results[0].boxes:
            # box.xyxy, box.cls, box.conf
            self.process_detection(box)
```

Python

### Estymacja głębokości (monocular)

MiDaS / Depth Anything: relative depth z 1 kamery. ~25 FPS Jetson. Dokładność relatywna, wymaga kalibracji skalowej z LiDAR. Dobra dla planowania ścieżki.

### Segmentacja semantyczna

SAM 2 (Meta) + YOLOv8-seg: real-time instance segmentation. DINOv2 jako backbone — zero-shot transfer na nowe klasy obiektów.

Kamera to najtańszy, najbogatszy informacyjnie sensor. Robot musi zamienić piksele w semantyczną wiedzę o środowisku.

## Metody detekcji i ich cechy

### YOLOv8 / YOLOv11

One-stage, anchor-free. 3–6ms GPU, 15ms Jetson AGX. COCO mAP 53. Najszybsze dla real-time robotyki. Model nano (3.2MB) na Raspberry Pi.

### RT-DETR

Transformer-based, bez NMS. 54.8 mAP COCO. Wyższa dokładność niż YOLO. 9ms A100. Dobry gdy ważność > szybkość.

### DINO / GroundedSAM

Open-vocabulary detection: 'find all bottles!'. Zero-shot bez fine-tuningu. 5–10FPS — dla robotyki manipulacyjnej, nie nawigacji.

### ArUco / AprilTag

Fiducial markers — deterministyczne, latencja < 1ms. Dokładność pozycji < 1mm przy kalibrowanej kamerze. Standard dla pick-and-place.

# SLAM: Simultaneous Localization and Mapping

## Problem SLAM formalnie

$$p(x_{1:t}, m \mid z_{1:t}, u_{1:t})$$

Dany: obserwacje  $z_{1:t}$  (sensory), sterowania  $u_{1:t}$ . Szukaj: trajektoria robotax<sub>1:t</sub> + mapa m.

### EKF-SLAM

Extended Kalman Filter. Stan = [robot\_pose, landmarks]. O(n<sup>2</sup>) złożoność, nie skaluje się. Historia, ale ważny baseline.

### GMapping / Gmapping (ROS)

Particle filter SLAM. 2D LiDAR. Dobry dla małych środowisk. Nadal używany w Turtlebot3 demos.

### Cartographer (Google)

Sparse pose graph + scan matching (CSM). 2D i 3D LiDAR. Submaps + loop closure. Przemysłowy standard dla AGV.

### RTAB-Map

RGB-D + LiDAR SLAM. Loop closure z bag-of-words (visual). Eksportuje mapę 3D do Nav2. Bardzo kompletne rozwiązanie.

### ORB-SLAM 3

Visual SLAM (kamera): ORB feature extraction → pose graph. Monocular/stereo/RGB-D. Stan akademickiego art. 2021.

SLAM rozwiązuje problem jajka i kury: zbuduj mapę żeby się zlokalizować, zlokalizuj się żeby budować mapę. Centralny problem robotyki mobilnej.

## SLAM pipeline: kluczowe komponenty

### Odometria (front-end)

Scan matching (ICP/NDT) lub visual odometry. Estymacja ruchu między klatkami. Szybkie (< 10ms), ale akumuluje błąd.

### Loop Closure

Wykrycie wizyty w poprzednio odwiedzonej lokalizacji. Feature matching lub place recognition (NetVLAD, Scan Context). Koryguje drift.

### Graph Optimization (back-end)

Pose graph: węzły=pozy, krawędzie=ograniczenia. Minimalizacja sumy kwadratów błędów. g2o, GTSAM, iSAM2. Rzadka macierz informacji.

### Mapa

Occupancy grid (2D: 0/1/unknown), voxel map (OctoMap 3D), landmark map (punkty 3D), topologiczna (węzły+krawędzie).

💡 Dla robotów indoor uruchom: `ros2 launch slam_toolbox online_async_launch.py` — gotowy SLAM 2D. Dla 3D outdoor: Cartographer z LiDAR 3D.

# Planowanie ścieżki: A\*, RRT\*, Dijkstra i Optymalizacja

## implementacja i heurystyki A\*

```
import heapq
def a_star(grid, start, goal):
    # heurystyka: odległość Manhattan
    h = lambda n: abs(n[0]-goal[0])+abs(n[1]-goal[1])
    open_set = [(h(start), start)]
    g_score = {start: 0}
    came_from = {}
    while open_set:
        cur = heapq.heappop(open_set)
        if cur == goal:
            path = []
            while cur in came_from:
                path.append(cur); cur=came_from[cur]
            return path[::-1]
        for dx,dy in [(-1,0),(1,0),(0,-1),(0,1)]:
            nb = (cur[0]+dx, cur[1]+dy)
            if grid[nb[0]][nb[1]] == 0: # wolna komórka
                g = g_score[cur] + 1
                if g < g_score.get(nb, float('inf')):
                    g_score[nb] = g
                    came_from[nb] = cur
                    heapq.heappush(open_set,(g+h(nb),nb))
    return None # brak ścieżki
```

Python

### Potencjalne pola (Potential Fields)

Cel = atraktor, przeszkody = repulsory. Szybkie, reaktywne. Wada: lokalne minima (robot utyka). Używane w local planner jako składowa.

### Inflation layer — costmap

Przeszkody paddinowane buforem (robot\_radius + margin). A\* planuje z uwzględnieniem. NavStack costmap2d obsługuje automatycznie.

Planer ścieżki odpowiada na pytanie: jak dojść z punktu A do B unikając przeszkód? Dwa poziomy: global planner + local planner.

## Algorytmy i ich porównanie

### Dijkstra

A\* z  $h=0$ . Gwarantuje optymalność. Wolniejszy niż A\*. Podstawa dla wielu wariantów.  $O((V+E)\log V)$ .

### A\* (A-star)

Najszybszy kompletny dla grid map.  $h$ =Manhattan (4-conn) lub Chebyshev (8-conn). Admissible heuristic → optymalny.

### D\* Lite

Dynamic A\* — replanning gdy zmienia się mapa. Świetny dla środowisk dynamicznych. Standard NASA Mars Rover.

### RRT / RRT\*

Szybkie drzewo losowych próbek. RRT\*: asymptotycznie optymalny. Dobry dla wysokich DOF (6-DOF arm). Nie daje optymalnej ścieżki dla 2D nav.

### Nav2 Smac Planner

A\* na lattice / Hybrid-A\* dla kinematic constraints (Ackermann). NavFn (Dijkstra-based). Oficjalny planer ROS 2.

# Nav2: Navigation Stack ROS 2, architektura i konfiguracja

Nav2 to kompletny system nawigacji dla ROS 2. Zastępuje move\_base z ROS 1.  
Modularny, lifecycle-managed, BehaviorTree-based.

## BT Navigator

Orchestrator oparty o Behavior Tree (BehaviorTree.CPP). Koordynuje recovery behaviors, planner, controller.

## Controller Server

Local planner (DWB/MPPI/TEB). Śledzi globalną ścieżkę wysyłając /cmd\_vel. Unika lokalnych przeszkód.

## AMCL (Localization)

Adaptive Monte Carlo Localization — particle filter na gotowej mapie. 500–2000 cząstek. Wymaga map\_server.

## Planner Server

Uruchamia global planner (NavFn/Smac). Wejście: /goal\_pose → wyjście: /plan (ścieżka na mapie).

## Costmap 2D

Global costmap (statyczna mapa + inflation) + Local costmap (sliding window 5×5m sensor data).

## Recovery Behaviors

Spin · Backup · Clear costmap · Wait. Uruchamiane gdy robot utknął. Zdefiniowane w BT XML.

```
ros2 launch nav2_bringup navigation_launch.py map:=/path/to/map.yaml use_sim_time:=True  
params_file:=nav2_params.yaml
```

```
ros2 topic pub /goal_pose geometry_msgs/PoseStamped '{header:{frame_id:"map"}, pose:{position:{x:3.0,y:1.5}}}'
```

# Sterowanie robotem: PID, regulatory i pętla zwrotna

## Implementacja PID z anti-windup

```
class PIDController:                                     Python
    def __init__(self, Kp, Ki, Kd,
                 output_limits=(-1.0,1.0)):
        self.Kp, self.Ki, self.Kd = Kp, Ki, Kd
        self.integral = 0.0
        self.prev_error = 0.0
        self.limits = output_limits

    def compute(self, setpoint, measured, dt):
        error = setpoint - measured
        # Anti-windup: nie sumuj gdy na limicie
        p_out = self.Kp * error
        d_out = self.Kd * (error-self.prev_error)/dt
        # Sprawdź limity przed integrowaniem
        raw = p_out + self.Ki*self.integral + d_out
        if self.limits[0] < raw < self.limits[1]:
            self.integral += error * dt
        i_out = self.Ki * self.integral
        output = p_out + i_out + d_out
        self.prev_error = error
        # Clamp output
        return max(self.limits[0],
                  min(self.limits[1], output))

# Zastosowanie: prędkość koła
pid = PIDController(Kp=1.2, Ki=0.5, Kd=0.05)
cmd = pid.compute(target_rpm, encoder_rpm, dt)
```

PID (Proportional-Integral-Derivative) to najpowszechniejszy regulator w robotyce. Szacuje się, że 95% pętli sterowania w przemyśle to regulatory PID lub PI.

## Metody strojenia PID

### Ziegler-Nichols (Z-N)

Zwiększaj  $K_p$  do oscylacji  $\rightarrow K_u, T_u$ . Oblicz:  $K_p=0.6K_u, T_i=0.5T_u, T_d=0.125T_u$ . Szybka metoda — może być zbyt agresywna.

### Tryb manualny + iteracyjny

Start:  $K_p$  mały,  $K_i=K_d=0$ . Zwiększaj  $K_p$  do oscylacji. Dodaj  $K_i$  dla steady-state error. Dodaj  $K_d$  dla tłumienia. Praktycznie najczęstszy.

### Auto-tuning (relay feedback)

Wbudowany w sterowniki Beckhoff/Siemens. Układ przełączający (relay)  $\rightarrow$  oscylacje kontrolowane  $\rightarrow$  auto-oblicza  $K_u, T_u$ .

### Cascade PID

Zewnętrzna pętla pozycji  $\rightarrow$  setpoint wewnętrznej pętli prędkości  $\rightarrow$  setpoint pętli prądu. Szybsze pętle wewnętrzne (1kHz current, 100Hz velocity).

### Zaawansowane: LQR, MPC

Linear Quadratic Regulator, optymalne przy modelowaniu stanu. MPC (Model Predictive Control), predykcja  $N$  kroków. Standard w cobotach i AV.

# Maszyny stanów i Behavior Trees, architektura decyzyjna

## Implementacja Behavior Tree w Python

```
import py_trees Python

# Liście (Behaviours)
class CheckBattery(py_trees.behaviour.Behaviour):
    def update(self):
        if battery_level > 20:
            return py_trees.common.Status.SUCCESS
        return py_trees.common.Status.FAILURE

class NavigateToGoal(py_trees.behaviour.Behaviour):
    def update(self):
        if nav_complete:
            return py_trees.common.Status.SUCCESS
        return py_trees.common.Status.RUNNING

# Drzewo: Sequence = AND, Selector = OR
root = py_trees.composites.Selector(
    "Root", memory=False)

patrol = py_trees.composites.Sequence(
    "Patrol", memory=False)
patrol.add_children([
    CheckBattery(),
    NavigateToGoal(),
    PickObject()])

recharge = py_trees.composites.Sequence(
    "Recharge", memory=False)
recharge.add_children([GoToCharger(), Charge()])

root.add_children([patrol, recharge])
```

Decyzja: co robot ma teraz robić?  
Maszyna stanów to dobry start, ale Behavior Trees  
(BT) skalują się lepiej dla złożonego zachowania.

## Porównanie FSM vs Behavior Trees

Aspekt	FSM	Behavior Tree
Skalowalność	Eksplozja liczby stanów/tranzycji przy złożoności $O(n^2)$	Hierarchiczna, modułowa — dodaj poddrzewo bez zmian istniejącego
Czytelność	Diagram stanów czytelny do ~20 stanów	XML/graficzny, narzędzia (Groot2) — wizualizacja w runtime
Reaktywność	Trudna zmiana priorytetu — wymaga nowych tranzycji	Selector re-evaluuje każdy tick — naturalny priorytet
Współbieżność	Wymaga przebudowy na Statecharts	Parallel composite — wbudowana równoległość
Debugging	Logi tranzycji stanów	Groot2 live visualization, każdy node status kolorowany

💡 Nav2 używa BehaviorTree.CPP v4 z gotowymi BT XML. Otwórz Groot2 IDE → Live Monitor podczas nawigacji, by zobaczyć aktywny węzeł drzewa w czasie rzeczywistym.

# MoveIt 2: Planowanie Ruchu Manipulatorów

MoveIt 2 to de facto standard planowania ruchu dla ramion robotycznych w ROS 2. Integruje IK, kolizje, trajektorie i sterowanie.

## MoveGroup Interface

Główne API. `move_group.setPoseTarget()` → `plan()` → `execute()`. Proste zadania w kilku liniach Pythona/C++.

## FCL Collision Check

Flexible Collision Library: sphere/box/mesh primitives. Sprawdza self-collision i environment. < 1ms per check.

## OMPL (planery)

Open Motion Planning Library: RRT\*, PRM\*, BIT\*, LBTRRT. Każdy obsługuje 6-DOF w sekundach. Domyślny: RRT Connect.

## KDL / TRAC-IK

Kinematics solver. TRAC-IK 3× szybszy i bardziej niezawodny niż KDL (78% → 99% success rate). Zawsze używaj TRAC-IK.

## Planowanie chwytania obiektów (pick and place)

```
# MoveIt 2 Python interface – pick & place
from moveit2 import MoveIt2
arm = MoveIt2(node, joint_names=["j1", "j2", "j3", "j4", "j5", "j6"],
              base_link="base_link", end_effector="tool0",
              group_name="manipulator")
# Zaplanuj do pozycji w przestrzeni kartezyjskiej
arm.set_pose_goal(position=[0.4, 0.2, 0.3],
                  quat_xyzw=[0, 0.707, 0, 0.707])
success = arm.plan() # OMPL planning
if success: arm.execute() # wysyła do ros2_control

# Trajektoria kartezyjska (linearna, nie joint-space)
waypoints = [[0.4,0.2,0.3],[0.4,0.2,0.1],[0.4,0.3,0.1]]
arm.set_cartesian_path_goal(waypoints, max_step=0.005) # 5mm
```

Python

💡 Uruchom MoveIt Setup Assistant (`ros2 launch moveit_setup_assistant setup_assistant.launch.py`) — generuje automatycznie SRDF, konfigurację collision matrix i launch files.

# Uczenie ze wzmocnieniem: PPO, SAC i Sim2Real Transfer

RL dla robotów: zamiast programować zachowanie, robot uczy się go przez próby i błędy w symulacji. Sim2Real: przenieś nauczoną politykę na prawdziwy hardware.

## PPO dla sterowania robotem: Stable-Baselines3

```
from stable_baselines3 import PPO
from stable_baselines3.common.env_util import (
    make_vec_env)
import gymnasium as gym

# Tworzenie środowiska (Gym / Gymnasium API)
env = make_vec_env("HalfCheetah-v4", n_envs=8)
# n_envs=8: równoległe środowiska → szybsze próbkowanie

model = PPO(
    "MlpPolicy",
    env,
    learning_rate=3e-4,
    n_steps=2048, # kroków zbieranych przed update
    batch_size=64,
    n_epochs=10,
    gamma=0.99, # discount factor
    gae_lambda=0.95, # GAE advantage estimation
    ent_coef=0.01, # entropia → eksploracja
    verbose=1)

model.learn(total_timesteps=1_000_000)
model.save("ppo_cheetah")
# Inferencja: obs, _ = env.reset()
# action, _ = model.predict(obs, deterministic=True)
```

Python

## Algorytmy RL dla robotów

### PPO (Proximal Policy Optimization)

On-policy. Stabilne, sample-efficient. Clip ratio  $\epsilon=0.2$ . Złoty standard. Spot (BD) locomotion, OpenAI Dexterous Hand nauczyły się PPO.

### SAC (Soft Actor-Critic)

Off-policy, maximum entropy RL. Automatyczny tuning temperatury. Bardziej sample-efficient niż PPO. Dobry dla ciągłych przestrzeni akcji (ramię).

### Sim2Real Transfer - Domain Randomization

Problem: sim2real gap (tarcie, masa, opóźnienia różne). Rozwiązanie: randomizuj parametry w symulacji → polityka uodporniona na wariancję. NVIDIA używa Isaac Gym + DR.

### Isaac Lab / IsaacGym

GPU-accelerated: 4096 środowisk równoległe na 1 GPU. 10× szybsze niż Gazebo. PyTorch natywnie. Robot learning state-of-art. AnyBotics ANYmal trenowany w Isaac.

💡 Zaczynij od Gymnasium MuJoCo envs (HalfCheetah, Ant, Humanoid) — stabilne benchmarki. Dopiero gdy polityka działa w symie, przenieś na hardware.

# Systemy wbudowane: STM32, Raspberry Pi, Jetson i RTOS

Robot to hierarchia komputerów: mikrokontroler ( $< 1\mu\text{s}$ , PWM/SPI)  $\rightarrow$  komputer pokładowy (nawigacja)  $\rightarrow$  PC (planowanie, ML). Każdy poziom ma inne wymagania.

## STM32F4/G4 (low-level ctrl)

Cortex-M4/M7, 168MHz. Sterowanie silnikami PWM, SPI do IMU, UART do czujników. Opóźnienie  $< 1\mu\text{s}$ . FreeRTOS lub bare-metal. micro-ROS  $\rightarrow$  DDS agent.

## Raspberry Pi 4/5 (mid-level)

ARM Cortex-A72, 4-core, 8GB RAM. ROS 2 natively. Brak gwarancji real-time (Linux). Dobry dla perception, planning. USB3  $\rightarrow$  kamera, WiFi, BT.

## NVIDIA Jetson Orin (AGX/NX)

12 TOPS NVDLA + GPU 1792 CUDA + ARM A78. Dedykowany robot AI. TensorRT inference YOLOv8  $< 3\text{ms}$ . Sterowanie robotem + ML na jednym module.

## BeagleBone Blue / OpenCR

Specjalizowane do robotów: OpenCR (Turtlebot3) – STM32 + IMU + motor drivers na jednej płycie. BeagleBone: PRU (200MHz real-time coprocessors).

## micro-ROS

ROS 2 na mikrokontrolerach (STM32/ESP32). micro-ROS Agent na RPi/PC. Topiki, serwisy przez XRCE-DDS (UDP/UART/CAN). STM32 + FreeRTOS oficjalnie wspierany.

## CAN Bus w robotach

ISO 11898, 1Mbit/s. Odporny na zakłócenia. Multi-master. Sterowniki silników ESCON/ODrive/VESC komunikują przez CAN. ROS 2: ros2\_socketcan.

## ROS 2 real-time (Apex.OS)

Apex.OS = certyfikowana ASIL-D dystrybucja ROS 2 z gwarancjami real-time. Używana w autonomicznych wózkach widłowych STILL.

## Real-Time Operating Systems

```
/* FreeRTOS – sterowanie silnikiem, STM32 */  
#include "FreeRTOS.h"  
#include "task.h"  
  
void motor_control_task(void *pvParam) {  
    TickType_t last_wake = xTaskGetTickCount();  
    for(;;) {  
        // Odczyt enkodera  
        int32_t pos = encoder_get_count();  
        // PID: setpoint  $\rightarrow$  PWM  
        float pwm = pid_compute(  
            target_pos, pos, 0.001f); // dt=1ms  
        motor_set_pwm(pwm);  
        // Precyzyjne 1kHz (1ms period)  
        vTaskDelayUntil(&last_wake,  
            pdMS_TO_TICKS(1));  
    }  
}  
// Priorytet: motor_task(5) > nav_task(3) > log(1)  
xTaskCreate(motor_control_task, "motor",  
    256, NULL, 5, NULL);
```

# Komunikacja niskopoziomowa: CAN, UART, SPI, I<sup>2</sup>C, EtherCAT

Każdy protokół ma swoje zastosowanie. Dobry inżynier robotyki wybiera protokół pasujący do wymagań: przepustowość, dystans, real-time, koszty.

## CAN Bus (ISO 11898)

≤ 1 Mbit/s  40m

Sterowniki silników (ODrive, VESC), IMU przemysłowy. Multi-master, priorytetyzacja. Samochody od 1986.

## UART / RS-485

≤ 4 Mbit/s  1200m

GPS modemy, LiDAR (RPLIDAR UART), debug console. Punkt-punkt lub multi-drop (RS-485). Asynchroniczny.

## SPI

≤ 50 Mbit/s  30cm

IMU (ICM-42688 10MHz SPI), Flash, enkodery absolutne. Full-duplex, synchroniczny. Master-slave.

## I<sup>2</sup>C

≤ 3.4 Mbit/s  1m

Czujniki dystansu, ekspandery GPIO, OLED display. Tylko 2 przewody (SDA+SCL). Adresowanie 7-bit.

## EtherCAT

≤ 100 Mbit/s  100m

Przemysłowe serwonapędy (Beckhoff AX5000). Jitter < 1μs. Każdy slave przetwarza ramkę w locie.

## USB 3 / PCIe

≤ 5 Gbit/s  5m

Kamery RGB-D (ZED, RealSense), LiDAR 3D (Ouster). Wysoka przepustowość danych.

# Symulacja — Gazebo Harmonic, Webots i NVIDIA Isaac Sim

Symulacja skraca czas developmentu 10x: testuj algorytmy bez ryzyka uszkodzenia hardware. Wierność symulacji to klucz do skutecznego Sim2Real.

## Gazebo Harmonic (nowy Gazebo)

Następca Gazebo Classic. Zbudowany od zera: Ignition/gz-sim. Lepszy multi-robot, pluginy w Ignition Transport, OGRE 2 rendering. Integracja Nav2/MoveIt 2 przez ros\_gz\_bridge. Standard ROS 2.

## Webots

Open-source, WSL-friendly. Prostszy start niż Gazebo. Wbudowane modele: TIAGo, Spot, UR10. Python supervisor API. Dobry dla dydaktyki.

## CoppeliaSim (V-REP)

Profesjonalny, komercyjny. Wbudowana odwrotna kinematyka IKfast, siły kontaktu, przenośnik taśmowy. Zbliżony do rzeczywistości fizycznej.

## NVIDIA Isaac Sim (Omniverse)

USD scene format. PhysX 5 physics. Fotorealistyczny rendering Lumen. 4096 równoległych środowisk GPU. Domain Randomization wbudowany. Przyszłość robotyki AI.

## Gazebo — SDF i uruchamianie świata:

```
# launch/simulation.launch.py
from launch import LaunchDescription
from launch_ros.actions import Node
from launch.actions import IncludeLaunchDescription

def generate_launch_description():
    return LaunchDescription([
        # Gazebo z customowym światem
        IncludeLaunchDescription(
            PythonLaunchDescriptionSource([
                gz_sim_pkg, "/launch/gz_sim.launch.py"
            ]),
            launch_arguments={
                "gz_args": "my_world.sdf -r"
            }.items(),
        # Bridge ROS 2 ↔ Gazebo Topics
        Node(package="ros_gz_bridge",
```

Python

## Modele URDF / SDF

URDF (XML): links, joints, visual, collision, inertia. xacro: makra i parametry. SDF: Gazebo native, więcej właściwości fizycznych. Eksport z Fusion 360 / SolidWorks, [Cubit Scan](#)

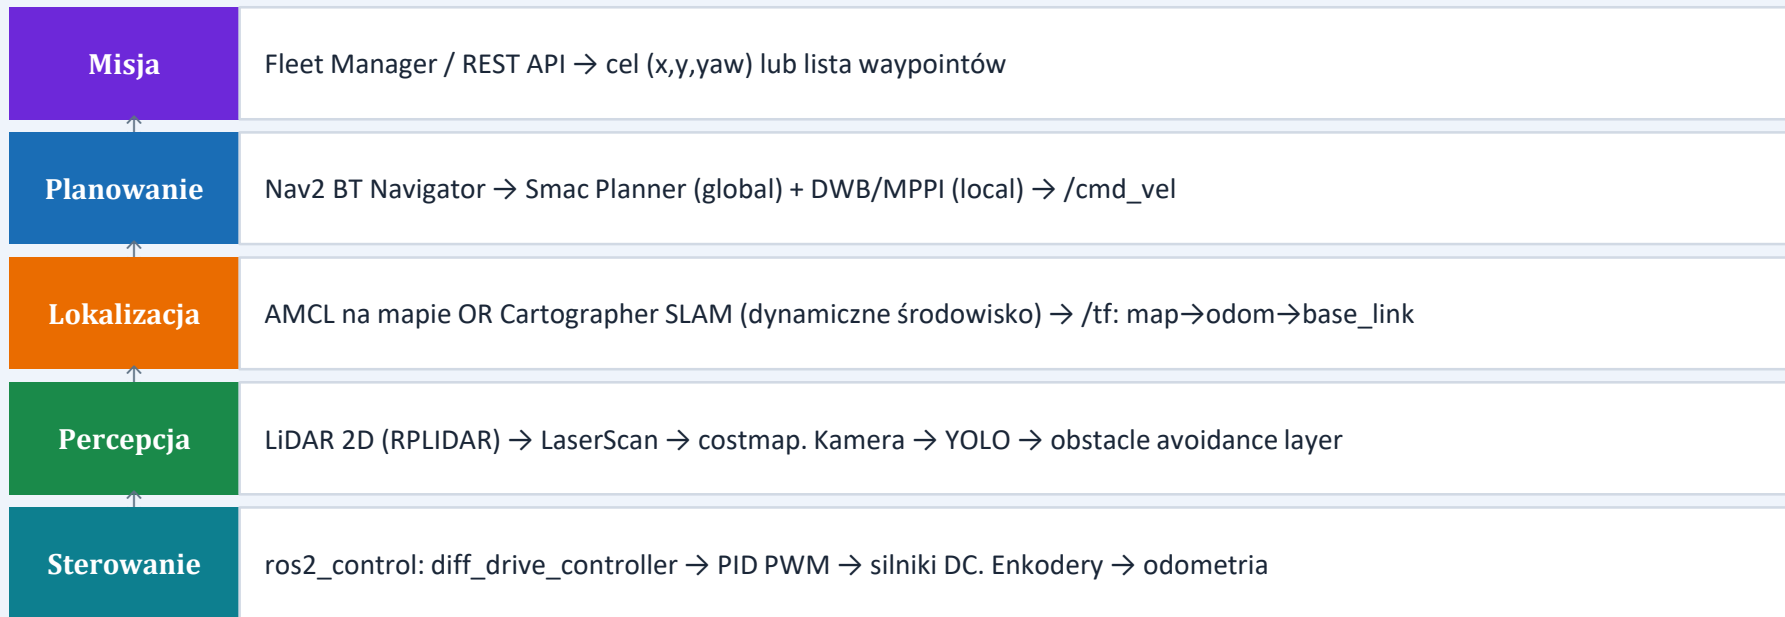
## ros2\_control + Gazebo

hardware\_interface::SystemInterface → Gazebo Plugin. Jeden kod kontrolera działa w symie i na hardware. Kluczowy wzorzec ROS 2.

# Integracja: pełny stack nawigacyjny dla AMR

AMR (Autonomous Mobile Robot) w magazynie: cel = dotarcie do punktu, podniesienie towaru, powrót. Wymaga integracji wszystkich komponentów.

## Pełny stack nawigacyjny → przepływ danych:



! Diagnostyka: `ros2 topic hz /scan` (sprawdź 10Hz LiDAR) · `ros2 topic echo /tf` (sprawdź transformacje) · `rviz2` → Add → TF · `rqt_graph` → sprawdź połączenia węzłów

# Coboty i bezpieczeństwo: ISO 10218, Power and Force Limiting

Cobot (collaborative robot) = robot pracujący bezpiecznie obok człowieka bez fizycznej bariery. Wymaga certyfikacji i analizy ryzyka.

## Tryby pracy cobota (ISO/TS 15066)

### SSM — Speed & Separation Monitoring

Kamera/LiDAR monitoruje dystans człowiek-robot. Prędkość robota spada proporcjonalnie do zbliżenia. Zatrzymanie przy <100mm.

### PFL — Power & Force Limiting

Czujniki siły/momentu w każdym stawie. Zatrzymanie gdy  $F > 150N$  lub  $\text{moment} > 80Nm$ . UR/KUKA/Fanuc cobots.

### HGP — Hand Guiding Port

Człowiek prowadzi ramię ręcznie (gravity compensation). Teach-by-demonstration. FT sensor na flanszu.

### STO — Safe Torque Off

Stop kategorii 0: natychmiastowe odcięcie napędu. Relay bezpieczeństwa + SIL 2. Zawsze jako ostateczność.

## komunikacja i safety UR10e

```
# UR10e przez ur_robot_driver (ROS 2)
# Prędkość max: 1m/s (safety-limited)
# Payload: 12.5kg, Reach: 1300mm

# joint_trajectory_controller → /joint_trajectory
from control_msgs.action import FollowJointTrajectory
from trajectory_msgs.msg import JointTrajectoryPoint

point = JointTrajectoryPoint()
point.positions = [0.0, -1.57, 1.57,
                  -1.57, -1.57, 0.0]
# [base, shoulder, elbow, w1, w2, w3] rad
point.time_from_start.sec = 2 # 2 sekundy

# Safety: tool_contact_threshold = 50N
# Jeśli FT sensor przekroczy → E-STOP
# Konfiguracja w PolyScope Safety Panel
```

### Analiza ryzyka (ISO 12100)

Identyfikacja zagrożeń → ocena ryzyka (Severity × Probability × Avoidability) → redukcja przez design → ostrzeżenia → PPE. Dokumentacja obowiązkowa dla CE.

### Popularne coboty 2024

UR10e (Universal Robots) · KUKA LBR iiwa · Fanuc CRX · ABB GoFa/Swifti · Franka Emika Panda (research standard) · Techman TM14.

💡 NEVER connect cobot directly to ROS 2 without safety controller in the loop. Używaj certified safety PLC (e.g. Pilz PNOZ) jako hardware guard.

# Systemy wielorobotowe: Koordynacja, Rój i Fleet Management

Wiele robotów może robić więcej niż jeden — ale koordynacja to nowy problem: unikanie kolizji, rozdzielanie zadań, komunikacja.

## Multi-robot w ROS 2 (namespace)

```
# Każdy robot = osobna przestrzeń nazw
# robot_1/cmd_vel, robot_2/cmd_vel
# robot_1/scan, robot_2/scan

# launch/multi_robot.launch.py
robots = [
    {"name": "robot_1", "x": 0.0, "y": 0.0},
    {"name": "robot_2", "x": 2.0, "y": 0.0},
    {"name": "robot_3", "x": 4.0, "y": 0.0},
]
for robot in robots:
    ld.add_action(Node(
        package="nav2_bringup",
        executable="bringup_launch.py",
        namespace=robot["name"],
        parameters=[
            {"use_namespace": True,
             "robot_name": robot["name"]},
        ]
    )))

# MAPF: Multi-Agent Path Finding
# CBS (Conflict-Based Search) dla optymalności
```

Python

## MAPF — planowanie wielu agentów

Conflict-Based Search (CBS): dekompozycja na single-agent + tree konfliktów. Suboptymalne: WHCA\* (windowed). Amazon Robotics: 750k robotów w magazynach.

## Fleet Management System (FMS)

Task allocation (aukcja, Hungarian method). Traffic management (virtual lanes, traffic lights). Open-source: OpenRMF. Komercyjny: MIR Fleet, OTTO Fleet.

## Robotics roju (Swarm Robotics)

### Flocking (Craig Reynolds Boids)

Trzy reguły: Separation (unikaj sąsiadów) + Alignment (wyrównaj prędkość) + Cohesion (trzymaj się grupy). Emergentne zachowanie z prostych reguł lokalnych.

### Stigmergy — komunikacja przez środowisko

Jak mrówki: zostawiaj ślad (virtual pheromone). Robot czyta/pisze do shared map. Nie wymaga bezpośredniej komunikacji. Skalowalny do tysięcy agentów.

### Kilobot / e-puck / Crazyflie

Kilobot (Harvard): 3cm, IR komunikacja, 1024 roju. e-puck 2: edukacyjny. Crazyflie 2.1: nano-dron, swarm flights z Crazyswarm2 ROS 2 package.

### Przeszkody: komunikacja i skalowanie

Bandwidth:  $N^2$  wiadomości dla all-to-all. Rozwiązanie: broadcast lokal. Konsensus (Raft/Paxos) przy centralizowanym FMS. ROS 2 DDS ograniczone do ~50 robotów bez tuningu.

### Amazon Robotics / Kiya

750k robotów Proteus w centrach dystrybucji. Siatka 30cm — roboty przywożą półki do człowieka. 3x szybszy fulfillment. \$775M akwizycja Kiva 2012.

# Studium przypadku: autonomiczny samochód (SAE L4)

AV (Autonomous Vehicle) to najbardziej wymagające wdrożenie robotyki: pełne bezpieczeństwo życia, każdy edge case musi być obsłużony.

## Percepcja

LiDAR 128-line (Luminar Iris) + kamera 360° (8x) + radar 4D (Continental ARS540). Sensor fusion: BEV (Bird's Eye View) representation.

## Predykcja

Przewidywanie zachowania pieszych/aut na 5s. Transformer-based (Wayformer, MTR). Multiple hypotheses z probability distribution.

## Planowanie

Structured prediction: reguły drogowe + optymalizacja trajektorii. MPC z constraint satisfaction. Waymo używa Monte Carlo rollouts.

## Sterowanie

Stanley / Pure Pursuit + MPC dla śledzenia ścieżki. Lat/Lon control: kierownica + gaz/hamulec. Aktuatory by-wire (EPS + EBS).

## Sprzęt obliczeniowy — NVIDIA DRIVE Thor / Orin

DRIVE Orin: 254 TOPS. DRIVE Thor (2025): 2000 TOPS. Redundancja 2+1: primary compute + safety monitor + lockstep. Fail-operational: 3s maneuver po awarii compute.

🚗 Porównanie 2024: Waymo One (L4, 25 miast USA) · Baidu Apollo Go · WeRide · Tesla FSD Beta (L2+, ADAS). Waymo: 0 fatalities / 10M km. Ludzie: 1.37 deaths / 100M km.

🏠 Apollo Open Platform: Baidu open-source AV stack. GitHub: ApolloAuto/apollo. 100+ modułów, własny simulator (Dreamview). Używany przez 200+ firm.

💡 Robot dostawczy (studium przypadku sl. 29) jest lepszym projektem niż AV — niższe prędkości (<20km/h), mniejsze ODD, bardziej osiągalny jako projekt studencki.

# Standardy bezpieczeństwa: ISO 10218, ISO 26262, IEC 61508

Bezpieczeństwo robotów to wymóg prawny (CE marking, OSHA) i etyczny. Systemy autonomiczne muszą dowieść bezpieczeństwa formalnie.

## Hierarchia standardów bezpieczeństwa

<b>IEC 61508</b>	Elektryczne/elektroniczne systemy safety-critical	<b>SIL 1-4</b>	Standard nadrzędny. Definiuje SIL (Safety Integrity Level). Podstawa dla ISO 26262 i ISO 10218.
<b>ISO 10218-1/2</b>	Roboty przemysłowe i komórki robotyczne	<b>PLd/SIL2</b>	Część 1: robot. Część 2: instalacja. Definiuje PL (Performance Level) a-e według EN ISO 13849-1.
<b>ISO/TS 15066</b>	Roboty współpracujące (coboty)	<b>PLd/SIL2</b>	Uszczegółowia 10218 dla cobotów: SSM, PFL, HGP tryby. BioMechanical Limit Tables dla sił zderzenia.
<b>ISO 26262</b>	Automotive ASIL (pojazdy drogowe)	<b>ASIL A-D</b>	ASIL D = najwyższy. Dotyczy AV, systemów ADAS. Deterministic failure rate $10^{-8}$ /h dla ASIL D.
<b>UL 4600 (AV)</b>	Pojazdy autonomiczne — brak kierowcy	<b>Safety Case</b>	Standard oparty o Safety Case (argumentacja). AWS, Waymo pracują z UL 4600. USA/CA AV regulations.

💡 Dla projektu studenckiego: przeprowadź uproszczoną analizę ryzyka (FMEA: co może pójść źle → skutek → zabezpieczenie). Minimum: E-STOP sprzętowy + ogranicznik prędkości.

# Studium przypadku: autonomiczny robot dostawczy

Starship Technologies, Nuro, Amazon Scout: roboty trotuar-level delivery.  
SAE L4 w ograniczonym ODD (trotuary, maks 20km/h, geofence).

## Architektura Starship (uproszczona)

### Sensory

9 kamer + LiDAR 2D + ultrasonic + GPS RTK. Kamera 360° główna. GPS RTK ±2cm dla fine localization przy skrzyżowaniach.

### Mapa

Wstępna mapa: HD survey vehicle. Update: każdy robot aktualizuje shared cloud map. Waypoints to trotuary, miejsca dostawy.

### Percepcja

Detekcja pieszych: kamera + depth estimation. Bariera 50cm → zatrzymanie. Cloud-assisted dla edge cases (video streaming).

### Nawigacja

A\* po graphie trotuarowym (pre-mapped). Local: DWA. Skrzyżowanie: oczekiwanie na zielone (detekcja sygnalizacji YOLO).

### Fleet

1000+ robotów w 100+ miastach. Centrala widzi wszystkie roboty real-time. Teleoperator interweniuje dla < 1% dostaw.

## Kluczowe metryki i wyzwania

```
# Specyfikacja techniczna (Starship Gen 3)
robot_specs = {
    "masa_kg" : 50,          # + 10kg ładunek
    "max_speed_kmh": 6,     # trotuar-safe
    "bateria_Wh" : 450,     # ~6h / 20km range
    "sensory" : "9 cam + LiDAR + USS + GPS RTK",
    "compute" : "NVIDIA Jetson Orin NX",
    "lockbox" : "code unlock via mobile app",
    # KPI produkcyjne:
    "delivery_success": 0.998, # 99.8% kompletnych
    "teleop_rate" : 0.008,    # 0.8% z interwencją
    "mtbf_hours" : 500,      # mean time between failure
}
```

Python

### Stairs & kerbs

Nie może wchodzić po schodach — musi omijać. HD mapa: predefiniowane przejścia dla pieszych z ramą.

### Pogoda

Deszcz i śnieg degradują kamery. IP65 obudowa. LiDAR odporny. Grzałki przednia kamera / koła w opcji.

### Agresywne dzieci

Rzeczywisty problem! Monitoring kamery + remote intervention. Stalowe obudowanie kół. Brak danych osobowych.

### Regulacje

Różne przepisy miasto/kraj. UK: Micromobility law. USA: state-by-state. EU: NIS2 dla connected robots.

💡 Projekt studencki: zbuduj mini delivery robot na ROS 2 + Nav2. Hardware: Turtlebot4 (€1200) lub samodzielnie RPi4 + RPLIDAR + DC motors + enkodery.

# Trendy: Embodied AI, Foundation Models i ROS 3

Rewolucja 2023–2025: Large Language Models + robotyka = roboty rozumiejące polecenia naturalne.  
Google, OpenAI, Tesla wchodzi w robotykę.

## RT-2 / RT-X (Google DeepMind)

Robotics Transformer: VLM (Visual-Language Model) end-to-end. Input: obraz + tekst polecenia. Output: akcje robota. Zero-shot transfer między robotami. Open X-Embodiment dataset 1M epizodów.

## Diffusion Policy / ACT

Imitation learning z demonstracji ludzkich: 30min demo → polityka robota. ACT: Action Chunking Transformer (Tony Zhao, Stanford). Mobile ALOHA: sprzątanie, gotowanie.

## ROS 3 / ROS 2 Iron+

ROS 2 Iron (LTS 2023): stable. Jazzy (2024). Kilpatrick (2026). ROS 3 w dyskusji: Rust-based communication, unified IDL, native TypeScript. micro-ROS 2.0 dla MCU.

## $\pi_0$ — Physical Intelligence

Foundation model dla humanoidów. Pre-trained na danych fizycznych → fine-tuned na task. Figure 01 / Boston Dynamics Atlas z LLM. 2025: pierwsze produktywne humanoidale w fabrykach.

## OpenVLA / Octo (open-source)

Open-source foundation models dla robotów. Octo (UC Berkeley): 800k demonstrations, fine-tunable. OpenVLA 7B: pełna waga dostępna. Jak HuggingFace dla robotów.

## Humanoidale (2025–2030)

Figure 01/02 (Figure AI) · Optimus Gen 2 (Tesla) · Atlas (BD) · Unitree H1. Cena target: \$20k (jak samochód). BYD używa Unitree G1 w fabrykach. AGI w ciele fizycznym.

# Projekt semestralny: wymagania i ocena

## Wymagania obligatoryjne

### Platform ROS 2 (Jazzy/Iron)

Turtlebot4 / własna platforma. Działające węzły, launch files, parametry YAML.

### SLAM + Mapa

Kartografowanie budynku. Zapis mapy (map\_saver). Lokalizacja AMCL na mapie.

### Autonomiczna nawigacja (Nav2)

Dojazd do 3 waypointów bez kolizji. Recovery behaviors działające.

### Percepcja obiektów

YOLOv8 lub detector ArUco. Wykrycie i klasyfikacja celu misji.

### Raport techniczny

Architektura, wyniki, metryki (success rate, avg time, collisions), wnioski.

## Kryteria oceny i harmonogram

### Funkcjonalność (40%)

Czy robot wykonuje zadanie? Success rate > 80% = pełne punkty.

### Architektura (25%)

Czysty kod, właściwe nazewnictwo, launch files, parametry nie w kodzie.

### Raport (20%)

Metryki ilościowe, wykresy, analiza błędów, wnioski, filmik demo.

Tydz. 2–4  
Platforma  
& ROS 2

Tydz. 5–7  
SLAM  
& Mapa

Tydz. 8–10  
Nav2  
& Percepcja

Tydz. 11–13  
Misja  
& Testy

Tydz. 14–15  
Demo  
& Raport

💡 Zaczynj w symulatorze Gazebo. Działający kod w simie → przenieś na hardware. Filmik demo jest obowiązkowy, nagraj nawigację autonomiczną i detekcję obiektu.

# Testowanie i diagnostyka: metryki, rviz2 i rosbag2

Dobry robot to testowany robot. Zdefiniuj metryki przed implementacją — nie po.  
Nagrywaj dane do późniejszej analizy.

## Kluczowe narzędzia diagnostyczne

### rviz2

Wizualizacja: TF tree, costmap, LaserScan, plan, path, markers.  
Niezbędny do debugowania percepcji i nawigacji.

### rqt\_graph

Graf węzłów i połączeń. Widoczne publisher/subscriber. Szybka diagnoza: czy topic istnieje? Kto publikuje?

### ros2bag2

Nagrywaj wszystkie topiki: `ros2 bag record -a`. Replay: `ros2 bag play`.  
Analiza post-mortem awarii i benchmarking.

### PlotJuggler

Real-time plot topików numerycznych. Lepszy niż `rqt_plot`. CSV eksport. Niezbędny dla strojenia PID i analizy trajektorii.

### Foxglove Studio

Nowoczesny rviz2 z przeglądarki. WebSocket bridge. Najlepszy UX dla prezentacji i remote debugging.

## Metryki ewaluacji robota nawigacyjnego

```
# Skrypt ewaluacji nawigacji
import rclpy, yaml
from nav2_simple_commander.robot_navigator import (
    BasicNavigator, TaskResult)

def evaluate_navigation(waypoints, n_trials=10):
    nav = BasicNavigator()
    results = {"success":0, "collisions":0,
              "times":[], "path_lengths":[]}
    for trial in range(n_trials):
        for wp in waypoints:
            start = time.time()
            nav.goToPose(wp)
            while not nav.isTaskComplete():
                time.sleep(0.1)
            result = nav.getResult()
            elapsed = time.time() - start
            if result == TaskResult.SUCCEEDED:
                results["success"] += 1
                results["times"].append(elapsed)
            else:
                results["collisions"] += 1

    # KPI
    sr = results["success"]/(n_trials*len(waypoints))
    print(f"Success Rate: {sr:.1%}")
    print(f"Avg Time: {np.mean(results['times']):.1f}s")
    return results
```

Python

## Metryki nawigacji

Success Rate (SR) · Average Time To Goal (ATTG) · Average Path Length (APL) · Path Length Ratio (PLR = actual/optimal) · Collision Rate per km

💡 Złota zasada: zawsze miej E-STOP w ręku podczas testów na hardware. Zanim puścisz robota, sprawdź: `max_vel < 0.5m/s`, `costmap inflation_radius > robot_radius`.

# Przyszłość autonomicznych robotów

## Embodied AI

LLM + Vision + robot = instrukcje językiem naturalnym. RT-2, OpenVLA,  $\pi_0$ . Zero-shot task transfer.

## Humanoidale

Figure 02, Tesla Optimus, Atlas — do fabryki 2025–2027. Cena docelowa <\$20k. AGI w ciele fizycznym.

## Swarm & Fleet

1M+ robotów Amazon, DHL. Open-source Fleet: OpenRMF. ROS 2 wspiera multi-robot out-of-box.

## Sim2Real (GPU)

Isaac Lab: 4096 środowisk/GPU. Domain randomization → zero-shot transfer. PPO polityka w 1h treningu.

## Safety & Trust

UL 4600, ISO 26262 ASIL-D. Formal verification (TLA+, Coq). Explainable AI dla robotów bezpiecznych.

## ROS 2 → Future

Jazzy LTS stabilne. ROS 3 w planowaniu (Rust-based). micro-ROS 2.0 STM32. ROS-Industrial standard.

## Kluczowe wnioski wykładu

- ROS 2 + Nav2 + MoveIt 2 to produkcyjny ekosystem — opanuj go, a skalujesz na dowolnego robota
- SLAM i planowanie ścieżki to rozwiązane problemy — kluczowe jest dobra inżynieria integracji i kalibracja
- Bezpieczeństwo nie jest opcją — E-STOP, analiza ryzyka i standardy ISO są częścią projektu, nie dodatkiem
- Sim2Real: zawsze testuj w symulacji najpierw. Gazebo + Isaac Lab skracają development 10x

Pytania, dyskusja i koniec