



## KARTA OPISU PRZEDMIOTU - SYLABUS

Nazwa przedmiotu

Systemy wbudowane i przetwarzanie brzegowe [S2AiR2-RiSA>PO3-SW]

### Przedmiot

Kierunek studiów

Automatyka i robotyka

Rok/Semestr

2/3

Studia w zakresie (specjalność)

Roboty i systemy autonomiczne

Profil studiów

ogólnoakademicki

Poziom studiów

drugiego stopnia

Język oferowanego przedmiotu

polski

Forma studiów

stacjonarne

Wymagalność

obieralny

### Liczba godzin

Wykład

15

Laboratorium

30

Inne

0

Ćwiczenia

0

Projekty/seminaria

0

### Liczba punktów ECTS

3,00

### Koordynatorzy

dr inż. Michał Fularz

michal.fularz@put.poznan.pl

### Wykładowcy

### Wymagania wstępne

Wiedza: Student powinien posiadać ogólną wiedzę na poziomie studiów inżynierskich, w szczególności w zakresie matematyki: algebry, analizy matematycznej, logiki oraz probabilistyki. Z zagadnień kierunkowych niezbędna jest wiedza na temat algorytmów przetwarzania obrazu, metod uczenia maszynowego i głębokiego, a także reprezentacji danych w systemach komputerowych. Umiejętności: Student powinien potrafić efektywnie wykorzystać komputer i posiadać umiejętności implementacji algorytmów oraz zadań programistycznych, w szczególności, w obszarze metod przetwarzania obrazów oraz uczenia głębokiego. Ponadto niezbędne są również umiejętności z zakresu rozwiązywania problemów oraz nabywania wiedzy ze wskazanych źródeł.

### Cel przedmiotu

Celem kursu jest zdobycie wiedzy z zakresu architektury systemów wbudowanych przeznaczonych do przetwarzania brzegowego. W szczególności dotyczy to wykorzystania algorytmów przetwarzania obrazów oraz głębokiego uczenia na urządzeniach o ograniczonej mocy obliczeniowej w aplikacjach związanych z automatyką i robotyką.

### Przedmiotowe efekty uczenia się

#### Wiedza:

Student, który ukończy kurs zdobędzie wiedzę z zakresu architektury, możliwości oraz zastosowań urządzeń wbudowanych do realizacji przetwarzania brzegowego w aplikacjach z dziedziny automatyki i robotyki. Będzie posiadał teoretyczną wiedzę na temat metod optymalizacji algorytmów, kwantyzacji wag modeli głębokiego uczenia, doboru modelu oraz konkretnych warstw. Student będzie w stanie właściwie dobrać typ i rodzaj urządzenia wbudowanego do rozwiązywanego problemu.

#### Umiejętności:

Student po ukończeniu kursu zdobędzie praktyczne umiejętności związane z wykorzystaniem urządzeń wbudowanych do realizacji zadania przetwarzania brzegowych, a w szczególności w obszarze wnioskowania sieci neuronowych w aplikacjach z zakresu automatyki i robotyki. Ponadto będzie umiał zastosować w praktyce zagadnienia takie jak kwantyzacja wag, konwersja modelu, wdrożenie algorytmu na urządzenia brzegowe. Rozwinie również kompetencje związane z wyszukiwaniem informacji w specyfikacjach producentów oraz rozwiązywaniem złożonych problemów matematycznych, algorytmicznych oraz programistycznych.

#### Kompetencje społeczne:

Student rozumie potrzebę i zna możliwości ciągłego doskonalenia się - podnoszenia kompetencji zawodowych, osobistych i społecznych, potrafi inspirować i organizować proces uczenia się innych osób. Posiada świadomość odpowiedzialności za pracę własną oraz gotowość podporządkowania się zasadom pracy w zespole

### Metody weryfikacji efektów uczenia się i kryteria oceny

Efekty uczenia się przedstawione wyżej weryfikowane są w następujący sposób:

Przedstawione efekty kształcenia zostaną zweryfikowane w następujący sposób:

- Wykład - test zaliczeniowy przeprowadzony na platformie eKursy.
- Laboratoria - praktyczny projekt końcowy.

### Treści programowe

Ogólny plan kursu obejmuje realizację następujących zagadnień:

1. Złożoność obliczeniowa algorytmów - metody analizy i wyznaczania.
2. Akceleracja obliczeń - metody.
3. Architektury systemów wbudowanych.
4. Przetwarzania brzegowe - zalety i wady, wyzwania.
5. Metody rozwoju oprogramowania dla urządzeń wbudowanych - zdalna komunikacja.
6. Złożoność obliczeniowa metod głębokiego uczenia, dobór modelu oraz warstw. Kwantyzacja wag sieci neuronowej.
7. Wprowadzenie do TinyML - wykorzystania algorytmów uczenia głębokiego na mikrokontrolerach.

### Tematyka zajęć

brak

### Metody dydaktyczne

Wykłady: prezentacje multimedialne (slajdy) ilustrowane praktycznymi przykładami użycia oprogramowania narzędziowego oraz fragmentami kodu realizującymi wybrane treści przedstawione podczas wykładu.

Ćwiczenia laboratoryjne realizowane zgodnie z instrukcjami na komputerach oraz dedykowanych urządzeniach wbudowanych (m.in. mikrokontrolery, komputery jednopłytkowe (SBC), dedykowane akceleratory sprzętowe, układy FPGA).

### Literatura

Podstawowa:

1. NVIDIA Jetson Software Documentation
2. R. Szeliski, Computer Vision: Algorithms and Applications, Springer, 2010
3. P. Warden, D. Situnayake, TinyML. Machine Learning with TensorFlow Lite on Arduino and Ultra-Low-Power Microcontrollers, O'Reilly Media, 2019

#### 4. Materiały uzupełniające opublikowane na platformie Moodle

Uzupełniająca:

1. I. Goodfellow, Y. Bengio, A. Courville, Deep Learning, MIT Press, 2016

2. A. Koul, S. Ganju, M. Kasam, Practical Deep Learning for Cloud, Mobile, and Edge, O'Reilly Media, 2019

#### Bilans nakładu pracy przeciętnego studenta

|                                                                                                                                                      | Godzin | ECTS |
|------------------------------------------------------------------------------------------------------------------------------------------------------|--------|------|
| Łączny nakład pracy                                                                                                                                  | 75     | 3,00 |
| Zajęcia wymagające bezpośredniego kontaktu z nauczycielem                                                                                            | 45     | 2,00 |
| Praca własna studenta (studia literaturowe, przygotowanie do zajęć laboratoryjnych/ćwiczeń, przygotowanie do kolokwίων/egzaminu, wykonanie projektu) | 30     | 1,00 |