



KARTA OPISU PRZEDMIOTU - SYLABUS

Nazwa przedmiotu

Elementy inteligencji obliczeniowej

Przedmiot

Kierunek studiów

Informatyka

Studia w zakresie (specjalność)

Poziom studiów

pierwszego stopnia

Forma studiów

stacjonarne

Rok/semestr

4/7

Profil studiów

ogólnoakademicki

Język oferowanego przedmiotu

polski

Wymagalność

obieralny

Liczba godzin

Wykład

30

Laboratoria

30

Inne (np. online)

0

Ćwiczenia

0

Projekty/seminaria

0

Liczba punktów ECTS

3

Wykładowcy

Odpowiedzialny za przedmiot/wykładowca:

dr hab. inż. Miłosz Kadziński

Instytut Informatyki PP

Wydział Informatyki i Telekomunikacji

ul. Piotrowo 2, 60-965 Poznań

milosz.kadzinski@cs.put.poznan.pl

Odpowiedzialny za przedmiot/wykładowca:

prof. dr hab. inż. Krzysztof Krawiec

Instytut Informatyki PP

Wydział Informatyki i Telekomunikacji

ul. Piotrowo 2, 60-965 Poznań

krzysztof.krawiec@cs.put.poznan.pl

Wymagania wstępne

Student rozpoczynający ten przedmiot powinien posiadać wiedzę z zakresu matematyki dyskretnej, algebry liniowej, optymalizacji kombinatorycznej, badań operacyjnych, wspomaganie decyzji i sztucznej inteligencji. Powinien posiadać umiejętności rozwiązywania podstawowych problemów programowania matematycznego, pozyskiwania informacji ze wskazanych źródeł oraz programowania w co najmniej jednym języku obiektowym. Powinien również rozumieć konieczność poszerzania swoich kompetencji w zakresie modelowania rzeczywistych problemów decyzyjnych i posługiwania się narzędziami informatycznymi do ich rozwiązywania. Ponadto w zakresie kompetencji społecznych student musi prezentować takie postawy jak uczciwość, odpowiedzialność, wytrwałość, ciekawość poznawcza, kreatywność, kultura osobista, szacunek dla innych ludzi.



Cel przedmiotu

Ogólnym celem jest poznanie przez studentów teoretycznych i praktycznych aspektów szeroko rozumianej algorytmicznej teorii decyzji i sieci neuronowych, a w szczególności:

1. Nabycie zaawansowanych umiejętności z zakresu teorii gier (ang. game theory), tj. analizy oraz identyfikacji optymalnych zachowań w ramach gier strategicznych, ekstensywnych oraz kooperacyjnych.
2. Zrozumienie mechanizmów funkcjonowania oraz algorytmów rozstrzygnięcia aukcji o charakterze prostym i kombinatorycznym.
3. Nabycie umiejętności wykorzystania granicznej analizy danych (ang. data envelopment analysis) w problemach badania efektywności jednostek decyzyjnych.
4. Poznanie podstawowych metod optymalizacji wielokryterialnej opartych na programowaniu liniowym i algorytmach genetycznych, a także nabycie umiejętności ich zastosowania do rozwiązywania rzeczywistych problemów optymalizacji.
5. Opanowanie wybranych metod związanych ze sztucznymi sieciami neuronowymi oraz zapoznanie się z paradygmatem głębokiego uczenia (ang. deep learning)
6. Poznanie algorytmów i metod uczenia głębokich sieci neuronowych.
7. Nabycie umiejętności stosowania głębokich sieci neuronowych do rozwiązywania problemów rozpoznawania obrazów, rozpoznawania mowy i przetwarzania języka naturalnego.

Przedmiotowe efekty uczenia się

Wiedza

K1st_W1: ma rozszerzoną i pogłębioną wiedzę z matematyki przydatną do formułowania i rozwiązywania złożonych zadań informatycznych

K1st_W4: ma uporządkowaną, podbudowaną teoretycznie wiedzę ogólną w zakresie algorytmów i złożoności, języków i paradygmatów programowania, sztucznej inteligencji oraz wspomagania decyzji

K1st_W5: ma szczegółową wiedzę nt. algorytmiki

K1st_W6: ma wiedzę o trendach rozwojowych i najistotniejszych nowych osiągnięciach w informatyce, w szczególności w zakresie inteligencji obliczeniowej

K1st_W8: zna podstawowe metody, techniki i narzędzia stosowane przy rozwiązywaniu prostych zadań informatycznych z zakresu analizy złożoności obliczeniowej, algorytmów i problemów, sztucznej inteligencji oraz wspomagania decyzji

Umiejętności

K1st_U1: pozyskiwać informacje z literatury oraz innych źródeł (w języku ojczystym i angielskim), integrować je, dokonywać ich interpretacji i krytycznej oceny, wyciągać wnioski oraz formułować i wyczerpująco uzasadniać opinie



K1st_U3: przygotować, w języku ojczystym i angielskim, dobrze udokumentowane opracowanie problemów z zakresu informatyki

K1st_U6: posługiwać się technikami informacyjno-komunikacyjnymi wykorzystywanymi przy realizacji przedsięwzięć informatycznych

K1st_U7: planować i przeprowadzać eksperymenty, w tym pomiary i symulacje komputerowe, interpretować uzyskane wyniki i wyciągać wnioski

K1st_U8: wykorzystać do formułowania i rozwiązywania zadań informatycznych metody analityczne, logiczne i eksperymentalne

K1st_U21: zaprojektować – zgodnie z zadaną specyfikacją – oraz zrealizować prosty system informatyczny, używając właściwych metod, technik i narzędzi

K1st_U22: sformułować i zaimplementować algorytm z użyciem przynajmniej jednego z popularnych narzędzi

Kompetencje społeczne

K1st_K1: rozumie, że w informatyce wiedza i umiejętności bardzo szybko stają się przestarzałe

K1st_K4: zna przykłady i rozumie przyczyny wadliwie działających systemów informatycznych, które doprowadziły do poważnych strat finansowych, społecznych lub też do poważnej utraty zdrowia, a nawet życia

Metody weryfikacji efektów uczenia się i kryteria oceny

Efekty uczenia się przedstawione wyżej weryfikowane są w następujący sposób:

Efekty kształcenia przedstawione wyżej weryfikowane są w następujący sposób:

Ocena formująca:

a) w zakresie wykładów:

- na podstawie odpowiedzi na pytania dotyczące materiału omówionego na wykładach.

b) w zakresie laboratoriów / ćwiczeń:

- na podstawie oceny bieżącego postępu realizacji zadań.

Ocena podsumowująca:

a) w zakresie wykładów weryfikowanie założonych efektów kształcenia realizowane jest przez:

- ocenę wiedzy i umiejętności wykazanych na zaliczeniu pisemnym o różnej charakterystyce problemów do rozwiązania: pytania testowe wielokrotnego wyboru, treść do uzupełnienia, proste zadania obliczeniowe lub algorytmiczne oraz zadania problemowe o większej złożoności egzamin jest zaliczony pod warunkiem uzyskania ponad połowy punktów.

- omówienie wyników zaliczenia,



b) w zakresie laboratoriów / ćwiczeń weryfikowanie założonych efektów kształcenia realizowane jest przez:

- ocenę wiedzy i umiejętności związanych z realizacją zadań laboratoryjnych poprzez kolokwium,
- ocenę sprawozdań przygotowywanych częściowo w trakcie zajęć, a częściowo po ich zakończeniu; ocena ta obejmuje także umiejętność pracy w zespole,
- ocenę umiejętności związanych z realizacją ćwiczeń laboratoryjnych oraz zadań programistycznych.

Uzyskiwanie punktów dodatkowych za aktywność podczas zajęć, a szczególnie za:

- omówienie dodatkowych aspektów zagadnienia,
- efektywność zastosowania zdobytej wiedzy podczas rozwiązywania zadane go problemu,
- umiejętność współpracy w ramach zespołu praktycznie realizującego zadanie szczegółowe w laboratorium,
- rozwój oprogramowania przydatnego w zajęciach laboratoryjnych.

Treści programowe

W ramach wykładu przedstawiane są następujące zagadnienia z zakresu teorii gier, granicznej analizy danych, optymalizacji wielokryterialnej:

- Pojęcia gry, gracza (agenta), strategii, macierzy wypłat oraz funkcji użyteczności. Przykłady prostych gier (dylemat więźnia, bitwa płci, gra w cykora). Zastosowania teorii gier w informatyce, ekonomii, socjologii i biologii.
- Gry strategiczne: rozumowanie strategiczne dla gier bez współpracy i z pełną informacją. Identyfikacja strategii dominujących (ang. dominant strategies) oraz strategii równowagi (ang. equilibrium strategies). Czysta równowaga Nasha (ang. pure Nash equilibrium) oraz Pareto optymalność.
- Strategie mieszane. Rozróżnienie czystej i mieszanej równowagi Nasha (ang. mixed Nash equilibrium). Istnienie oraz identyfikacja mieszanych równowag Nasha. Złożoność obliczeniowa dla gier o większych wymiarach. Praktyczne wykorzystanie równowagi Nasha. Strategie ściśle dominujące oraz iteracyjna eliminacja strategii. Strategie minimax i twierdzenie minimax dla gier o sumie zerowej. Równowaga skorelowana (ang. correlated equilibrium).
- Gry rozległe (ekstensywne): reprezentacja w postaci drzewa dla gier z pełną informacją, strategie rozłożone w czasie, określenie najlepszej odpowiedzi przy wzięciu pod uwagę kolejności podejmowania akcji. Perfekcja we fragmencie gry. Algorytm wstecznej indukcji. Wprowadzenie do gier z niepełną informacją. Strategie mieszane i zachowawcze.
- Gry iterowane: iterowany dylemat więźnia, skończona i nieskończona powtarzalność, gry stochastyczne. Aspekty uczenia w grach iterowanych. Równowaga i racjonalność w grach nieskończenie powtarzalnych.



- Gry koalicyjne (kooperacyjne) ze współpracą, wartość Shapley'a, rdzeń w procesie formowania koalicji.
- Wybrane metody optymalizacji wielokryterialnej oparte na sumie ważonej oraz epsilon-constraint method oraz podstawowych algorytmach ewolucyjnych: NSGA-II i SPEA2.
- Graniczna analiza danych (ang. data envelopment analysis): badanie efektywności jednostek decyzyjnych, modele CCR i BCC nastawione na zmniejszenie nakładów lub zwiększenie efektów; super-efektywność, efektywność krzyżowa.

Z zakresu sztucznych sieci neuronowych i głębokiego uczenia omówione zostaną:

- Podstawowe pojęcia z zakresu sieci neuronowych: sztuczny neuron, funkcja aktywacji, perceptron, sieci wielowarstwowe, jednokierunkowe.
- Metody uczenia sieci neuronowych – wsteczna propagacja błędów (ang. backpropagation), uczenie typu Hebb'a i typu konkurencyjnego; techniki inicjalizacji wag sieci, stochastyczne maskowanie neuronów (ang. dropout), normalizacja sygnału uczącego (ang. batch normalization), klasyczne metody regularyzacji wag (ang. regularization). Omówienie funkcji straty (ang. loss function) dla problemu klasyfikacji, regresji i predykcji strukturalnej (ang. structured prediction). Adaptatywne algorytmy sterowania prędkością uczenia (Adagrad, RMSProp).
- Konwolucyjne sieci neuronowe: operacje splotu (ang. convolution) i agregacji (ang. pooling), budowa warstwy konwolucyjnej, współdzielenie parametrów (ang. parameter sharing), lokalne połączenia pomiędzy neuronami (ang. local connectivity).
- Głębokie uczenie: pojęcie, zalety oraz wyzwania stawiane przez głębokie architektury sieci, omówienie technik uczenia głębokich sieci, m.in. nienadzorowane uczenie warstw sieci (ang. layer-wise unsupervised pretraining), uczenie pół-nadzorowane (ang. semi-supervised learning), transfer wiedzy (ang. transfer learning), sieci typu autoenkoder (ang. autoencoders), sieci rezydualne (ang. residual networks).
- Rekurencyjne sieci neuronowe: problem modelowania sekwencji, sieci LSTM (ang. long short-term memory) oraz GRU (ang. gated recurrent unit).
- Wybrane zastosowania: widzenie komputerowe (ang. computer vision), rozpoznawanie mowy (ang. speech recognition), przetwarzanie języka naturalnego (ang. natural language processing).

Poszczególne zagadnienia omawiane w ramach wykładu są ilustrowane zadaniami podczas ćwiczeń laboratoryjnych. Ponadto studenci analizują rzeczywiste problemy decyzyjne (ang. case study), które pozwalają na zastosowania wiedzy nt. poznanych metodologii w praktyce.

Metody dydaktyczne

Wykład: prezentacja multimedialna uzupełniona przykładami podawanymi na tablicy, demonstracja wybranych systemów z dziedziny inteligencji obliczeniowej, w tym algorytmicznej teorii decyzji oraz sieci neuronowych.



Ćwiczenia laboratoryjne: rozwiązywanie zadań, ćwiczenia praktyczne i programistyczne, wykonywanie eksperymentów, dyskusja, praca w zespole, studium przypadków, demonstracja wybranych systemów, generowanie realnych problemów decyzyjnych i rozwiązywanie ich metodami dostępnymi w laboratorium, pokaz multimedialny.

Literatura

Podstawowa

1. P. Straffin. Teoria gier, Wydawnictwo Naukowe Scholar, Warszawa, 2001.
2. J. Branke, K. Deb, K. Miettinen, R. Słowiński. Multiobjective Optimization: Interactive and Evolutionary Approaches, Springer, Berlin, 2008.
3. I. Goodfellow, Y. Bengio, A. Courville. Deep Learning: Systemy uczące się. Wydawnictwo Naukowe PWN, 2018.
4. C. M. Bishop. Neural Networks for Pattern Recognition, Oxford University Press, 1995.

Uzupełniająca

1. M.J. Osborne. An Introduction to Game Theory. Oxford University Press, 2004.
2. P. Cramton, Y. Shoham, R. Steinberg, Combinatorial Auctions, MIT Press, Boston, 2006.
3. A. Géron. Hands-On Machine Learning with Scikit-Learn and TensorFlow, O'Reilly Media, 2017.
4. M. A. Nielsen. Neural Networks and Deep Learning, Determination Press, 2015.

Bilans nakładu pracy przeciętnego studenta

| | Godzin | ECTS |
|--|--------|------|
| Łączny nakład pracy | 99 | 3,0 |
| Zajęcia wymagające bezpośredniego kontaktu z nauczycielem | 64 | 1,9 |
| Praca własna studenta (przygotowanie do ćwiczeń laboratoryjnych, dokończenie sprawozdań z ćwiczeń laboratoryjnych, napisanie programów, uruchomienie i weryfikacja, zapoznanie się ze wskazaną literaturą/materiałami dydaktycznymi, przygotowania do zaliczenia) ¹ | 35 | 1,1 |

¹ niepotrzebne skreślić lub dopisać inne czynności