

DOKTORSKI STUDIJ

OBRAZAC ZA PREDMET

Naziv predmeta	Napredno upravljanje za energetske učinkovitost i odziv potrošnje na pametnim mrežama
Ime i prezime nastavnika	Tea Žakula Andrej Jokić
Status predmeta	Izborni smjera
ECTS bodovi	6
Smjer doktorskog studija	Procesno-energetski smjer
Područja istraživanja koje pokriva predmet	Energetsko i procesno inženjerstvo Inženjersko modeliranje i računalne simulacije
Sadržaj i ciljevi kolegija	Cilj predmeta je osposobiti studente za modeliranje, analizu i uvođenje naprednog upravljanja s ciljem povećanja energetske učinkovitosti i odziva potrošnje na pametnim mrežama. Praktični primjeri koji će se obrađivati uključuju tipične inženjerske procese i sustave iz sektora zgradarstva i industrije. Predmet će biti podijeljen u poglavlja koja obrađuju a) osnovne metode naprednog upravljanja i mogućnosti sudjelovanja potrošača na pametnim mrežama, b) osnove teorije i primjene optimizacijskih metoda, c) oblikovanje modela za simulaciju dinamičkog odziva sustava na poremećajne varijable, d) planiranje eksperimenta za prikupljanje podataka potrebnih za kalibraciju i potvrdu točnosti modela, e) provođenje kalibracije, potvrde točnosti te analize osjetljivosti modela, f) oblikovanje optimizacijske funkcije i matematičkih algoritama za njeno rješavanje, g) razrada metodologije uvođenja naprednog upravljanja u realni proces i procjena investicijskih troškova, h) analiza ušteda energije i operativnih troškova. U sklopu predmeta predviđen je rad na inovativnim samostalnim projektima koji će uključiti mnoge od ovih koncepata u svrhu uvođenja naprednog upravljanja i optimizacije odziva potrošnje sustava, a temeljit će se na računalnim simulacijama i/ili eksperimentalnim mjerenjima.

Ishodi učenja	Nakon uspješno savladanog kolegija student će moći: □ predložiti metodu naprednog upravljanja na specifičnom primjeru sustava i analizirati mogućnost njegovog uključivanja u pametnu mrežu i sudjelovanja na tržištu energije □ oblikovati pojednostavljeni model za simulaciju dinamičkog odziva sustava □ provesti planiranje eksperimenta za prikupljanje podataka potrebnih za kalibraciju i potvrdu točnosti pojednostavljenog modela □ provesti kalibraciju, potvrdu točnosti te analizu osjetljivosti pojednostavljenog modela □ oblikovati optimizacijski problem i matematički algoritam za njegovo rješavanje □ predložiti metodologiju uvođenja naprednog upravljanja u realni proces i napraviti procjenu in
Način izvođenja nastave	- predavanje - seminari i radionice - samostalni zadaci - mentorski rad
Osnovna literatura	1. Boyd S, Vandenberghe L. Convex Optimization. Cambridge University Press, New York, USA, 2004. 2. Mayne D. Q., Rawlings J. B., Rao C. V., Scokaert P. O. M. 2000. Constrained model predictive control: Stability and optimality. Automatica 36, pages 789-814. 3. Qin S. J., Badgwell T. A. 2003. A survey of industrial model predictive control technology. Control Engineering Practice 11, pages 733–764.
Dopunska literatura	1. Maciejowski J. Predictive Control with Constraints. Prentice Hall, 2000.
Način polaganja ispita	Konačna ocjena bit će formirana na temelju: samostalnog projekta (50%) te usmenog ispita (50%).
Način praćenja kvalitete i uspješnosti izvedbe kolegija	(1) Samostalni projekt, (2) Usmeni ispit, (3) Povratne informacije na svakom satu i kroz forum na portalu e-ucenje.fsb.hr (sustav Moodle)

1. [1] Blum D., Zakula T., Norford L. 2016. Opportunity cost quantification for ancillary services provided by heating, ventilating, and air-conditioning systems. IEEE Transactions on Smart Grid 8 (3).
 2. [2] Zakula T., Armstrong P., Norford L. 2014. Modeling environment for model predictive control of buildings. Energy and Buildings 85.
-
1. [1] Hermans R.M., Lazar M., Jokić A. 2014., Stabilization of interconnected dynamical systems by online convex optimization. International Journal of Robust and Nonlinear Control; Volume 24, Issue 10, pages 1467-1487.
 2. [1] Hermans, Ralph M.; Lazar, Mircea; Jokić, Andrej. 2013. Distributed Lyapunov-based Model Predictive Control, poglavlje u knjizi Distributed MPC Made Easy Maestre, Jose M. ; Negenborn, Rudy R. (ur.). Dordrecht Heidelberg London New York: Springer,. str. 1-15