



Ministerul Educației și Cercetării
Universitatea „Valahia” din Târgoviște
Scoala Doctorală de Științe Inginerești

FIȘA DISCIPLINEI

1. Date despre program

1.1 Instituția de învățământ superior	Universitatea „Valahia” din Targoviște
1.2 Facultatea/Departamentul	Instituția Organizatoare de Studii Universitare de Doctorat
1.3 Departamentul	Școala Doctorală de Științe Inginerești
1.4 Domeniul de studii	Ingineria sistemelor
1.5 Ciclul de studii	Doctorat
1.6 Programul de studii/Calificarea	-

2. Date despre disciplină

2.1 Denumirea disciplinei	Studiu individual 3 (Inteligență Artificială (AI) aplicată în Scheduling Dinamic)						
2.2 Titularul activităților de curs / Conducător doctorat	Prof. univ. dr. ing. Eugenia MINCĂ						
2.3 Titularul activităților de seminar/laborator							
2.4 Anul de studiu	I	2.5 Semestrul	I	2.6 Tipul de evaluare	C	2.7 Regimul disciplinei	OB S

3. Timpul total estimat (ore pe semestru al activităților didactice)

3.1 Număr de ore pe săptămână	-	din care: 3.2 curs	-	3.3 seminar/laborator	-
3.4 Total ore din planul de învățământ	-	din care: 3.5 curs	-	3.6 seminar/laborator	-
Distribuția fondului de timp					Ore
Studiul după manual, suport de curs, bibliografie și notițe					-
Documentare suplimentară în bibliotecă, pe platformele electronice de specialitate și pe teren					145
- Studiul bibliografiei recomandate (manuale, monografii, articole ISI, standarde, baze de date) / 90h					
- Documentare suplimentară în biblioteci și baze de date științifice (Scopus, Web of Science, Springer, IEEE etc.) / 45h					
- Elaborarea sintezelor bibliografice, analizelor critice și portofoliului individual de studiu / 35h					
Pregătire seminarii/laboratoare, teme, referate, portofolii și eseuri					-
Tutoriat					20
Examinări (pregătirea și susținerea colocviului)					10
Alte activități					-
3.7 Total ore studiu individual					175
3.8 Total ore pe semestru					175
3.9 Numărul de credite					7

4. Precondiții (acolo unde este cazul)

4.1 de curriculum	
4.2 de competențe	

5. Condiții (acolo unde este cazul)

5.1 de desfășurare a cursului	
5.2 de desfășurare a seminarului/laboratorului	

6. Obiectivele disciplinei (reieșind din grila competențelor specifice acumulate)

6.1 Obiectivul general al disciplinei	Dezvoltarea capacității studentului-doctorand de a analiza critic și de a valorifica literatura științifică privind metodele de Inteligență Artificială (AI) aplicate în Scheduling Dinamic, cu accent pe Machine Learning, Deep Reinforcement Learning și Multi-Agent Reinforcement Learning, în vederea evaluării și selectării soluțiilor capabile să adapteze planificarea proceselor de producție la perturbații și incertitudini și a fundamentării cadrului conceptual și metodologic și a direcției proprii de cercetare doctorală în domeniul Ingineriei sistemelor.
6.2 Obiectivele specifice	- aprofundarea cunoștințelor privind principiile și metodele de Inteligență Artificială (AI) utilizate pentru planificarea și replanificarea dinamică a proceselor de producție, cu accent pe adaptarea deciziilor la modificările stării sistemului; - dezvoltarea capacității de documentare științifică utilizând baze de date internaționale și surse bibliografice relevante privind metodele de Machine Learning, Deep Reinforcement Learning (DRL) și Multi-Agent Reinforcement Learning (MARL) aplicate în Scheduling Dinamic; - formarea competențelor de analiză critică, comparare și evaluare a metodelor AI utilizate pentru Scheduling Dinamic, inclusiv a abordărilor bazate pe DRL/MARL, Graph Neural Networks, meta-euristici și algoritmi evolutivi; - aprofundarea metodelor de planificare și replanificare dinamică în condiții de perturbații și incertitudini, cu accent pe defectarea echipamentelor, sosirea dinamică și urgentă a comenzilor, constrângerile de resurse și cerințele privind performanța și eficiența energetică a sistemelor de producție; - identificarea tendințelor actuale, a avantajelor și limitărilor soluțiilor AI pentru Scheduling Dinamic, inclusiv a posibilităților de integrare cu Digital Twin și arhitecturile Cloud-Edge pentru luarea deciziilor și replanificarea în timp real; - dezvoltarea capacității de elaborare a unei sinteze bibliografice argumentate, de fundamentare a cadrului conceptual și metodologic și de definire a direcției proprii de cercetare doctorală privind aplicarea Inteligenței Artificiale în Scheduling Dinamic.

7. Rezultatele învățării

7.1 Cunoștințe (<i>Rezultatul asimilării de informații prin învățare. Cunoștințele reprezintă ansamblul de fapte, principii, teorii și practici legate de un anumit domeniu de muncă sau de studiu. Pot fi teoretice și/sau faptice</i>)	La finalizarea disciplinei, studentul-doctorand/absolventul: - demonstrează cunoștințe avansate privind principiile și metodele de Inteligență Artificială (AI) utilizate pentru planificarea și replanificarea dinamică a proceselor de producție; - cunoaște principiile și arhitecturile metodelor de Machine Learning, Deep Reinforcement Learning (DRL) și Multi-Agent Reinforcement Learning (MARL) aplicate în Scheduling Dinamic; - înțelege mecanismele de reprezentare a stărilor, acțiunilor și constrângerilor sistemului și de adaptare a deciziilor de scheduling la perturbații, incertitudini și modificări ale mediului de producție; - cunoaște principalele abordări AI utilizate pentru Scheduling Dinamic, inclusiv DRL/MARL, Graph Neural Networks, meta-euristici și algoritmi evolutivi, precum și posibilitățile de integrare cu Digital Twin și arhitecturi Cloud-Edge.
7.2 Aptitudini (<i>Capacitatea de a aplica cunoștințe și de a utiliza know-how pentru a duce la îndeplinire sarcini și a rezolva probleme. Aptitudinile sunt descrise ca fiind cognitive (implicând utilizarea gândirii logice, intuitive și creative) sau practice (implicând dexteritate manuală și utilizarea de metode, materiale, unelte și instrumente)</i>)	Studentul-doctorand /absolventul este capabil: - să identifice, selecteze și analizeze critic literatura științifică relevantă privind metodele AI aplicate în Scheduling Dinamic; - să analizeze comparativ metodele ML, DRL și MARL și să evalueze adecvarea acestora pentru diferite probleme de planificare și replanificare dinamică; - să compare și să evalueze soluțiile AI din perspectiva capacității de adaptare la defectarea echipamentelor, sosirea dinamică sau urgentă a comenzilor, constrângerile de resurse și alte perturbații ale sistemului de producție; - să analizeze metodele AI pentru Scheduling Dinamic în raport cu criteriile privind performanța producției, eficiența energetică, robustețea și capacitatea de adaptare în timp real; - să identifice avantajele, limitările și lacunele soluțiilor existente și să fundamenteze cadrul conceptual și metodologic și direcția proprie de cercetare privind aplicarea Inteligenței Artificiale în Scheduling Dinamic.
7.3 Responsabilitate și autonomie (<i>Capacitatea cursantului de a aplica în mod autonom și responsabil cunoștințele și aptitudinile sale</i>)	Studentul-doctorand /absolventul: - desfășoară în mod autonom activități de documentare, analiză critică și sinteză privind metodele AI aplicate în Scheduling Dinamic, cu respectarea principiilor eticii și integrității academice; - își asumă responsabilitatea pentru selectarea, evaluarea și interpretarea critică a metodelor și algoritmilor AI relevanți pentru problema de scheduling analizată; - argumentează în mod independent alegerea metodelor AI și a criteriilor utilizate pentru evaluarea soluțiilor de planificare și replanificare dinamică;

- dezvoltă în mod autonom cadrul conceptual și metodologic și își asumă responsabilitatea pentru fundamentarea științifică a direcției proprii de cercetare privind Inteligența Artificială aplicată în Scheduling Dinamic.

8. Conținuturi

8.2 Studiu individual	Metode de predare	Observații
Studierea bibliografiei fundamentale privind principiile și metodele de Inteligență Artificială (AI) utilizate pentru planificarea și replanificarea dinamică a proceselor de producție, cu accent pe formularea problemelor de Dynamic Scheduling, reprezentarea stărilor și constrângerilor sistemului și adaptarea deciziilor la modificările mediului de producție.	Studiu individual, analiză bibliografică	45 h
Documentarea în baze de date științifice privind metodele de Machine Learning, Deep Reinforcement Learning și Multi-Agent Reinforcement Learning utilizate pentru Dynamic Scheduling, cu accent pe sistemele de producție flexibile, mecanismele de învățare și decizie, coordonarea agenților și utilizarea Graph Neural Networks, meta-euristicilor și algoritmilor evolutivi.	Documentare în baze de date, analiză critică	25 h
Analiza critică și comparativă a literaturii privind metodele AI pentru Scheduling Dinamic în condiții de incertitudine și perturbații, cu evaluarea capacității acestora de adaptare la defectarea echipamentelor, sosirea dinamică și urgentă a comenzilor, constrângerile de resurse, cerințele de mentenanță și obiectivele de eficiență energetică și performanță a producției.	Analiză comparativă, sinteză bibliografică	25 h
Elaborarea unei sinteze bibliografice privind tendințele actuale și direcțiile emergente de cercetare referitoare la utilizarea Inteligenței Artificiale în Scheduling Dinamic, cu accent pe integrarea metodelor DRL/MARL cu Digital Twin și arhitecturile Cloud-Edge, identificarea avantajelor și limitărilor soluțiilor existente și fundamentarea cadrului conceptual și metodologic al cercetării doctorale.	Elaborare individuală, redactare academică	30 h
Consultări periodice cu titularul disciplinei și/sau conducătorul de doctorat privind bibliografia, direcțiile de cercetare și interpretarea critică a rezultatelor din literatura de specialitate.	Tutoriat, discuții individuale	20 h
Pregătirea și susținerea colocviului pe baza studiului individual și a raportului de documentare realizat.	Studiu individual, prezentare și susținere	30 h
Bibliografie		
[1.] Tang, Y., et al. (2026). Deep Reinforcement Learning for Flexible Job Shop Scheduling with Random Job Arrivals. arXiv preprint. [2.] Zhang, C., et al. (2025). Optimization of Dynamic Scheduling for Flexible Job Shops Based on Multi-Agent Deep Reinforcement Learning. Processes Journal. [3.] Wang, H., & Wang, J. (2024). Deep reinforcement learning for dynamic flexible job shop scheduling with state transition and action masking. International Journal of Production Research, 62(8), 2845-2864. [4.] Du, Y., & Xi, L. (2025). A collaborative multi-agent deep reinforcement learning approach for dynamic scheduling in smart manufacturing cells. IEEE Transactions on Industrial Informatics, 21(3), 1845-1857. [5.] Liu, R., & Zhang, S. (2023). Dynamic flexible job shop scheduling based on deep reinforcement learning with graph neural networks. Journal of Manufacturing Systems, 68, 112-125. [6.] Zhang, C., & Song, W. (2025). Resilient dynamic scheduling for flexible manufacturing systems under machine breakdowns: A deep reinforcement learning approach. Computers & Industrial Engineering, 190, 110042. [7.] Kuhnle, J., & Lanza, G. (2024). Autonomous production control using deep reinforcement learning in highly flexible manufacturing systems. CIRP Annals, 73(1), 413-416. [8.] Li, X., & Gao, L. (2023). An artificial intelligence-driven meta-heuristic for real-time dynamic scheduling in flexible assembly lines. IEEE Transactions on Automation Science and Engineering, 20(2), 915-929. [9.] Zhao, F., & CP, CP. (2025). Graph Neural Networks integrated with genetic algorithms for dynamic scheduling under uncertainty. Applied Soft Computing, 152, 111204. [10.] Wang, Y., & Cheng, R. (2024). Surrogate-assisted evolutionary algorithm using machine learning for energy-efficient dynamic job-shop scheduling. Swarm and Evolutionary Computation, 85, 101480. [11.] Marouf, W., & Pistikopoulos, E. N. (2026). Integrating machine learning classifiers with mathematical programming for fast dynamic scheduling in continuous plants. Computers & Chemical Engineering, 193, 108510. [12.] Shao, W., & Pi, D. (2023). A machine learning-based hyper-heuristic for dynamic flexible job shop scheduling with sequence-dependent setup times. IEEE Transactions on Cybernetics, 53(7), 4452-4465. [13.] He, Z., Li, N., Ran, N., Li, L., & Seatzu, C. (2026). Dynamic Scheduling for Flexible Manufacturing Systems Based on Multi-Agent Deep Reinforcement Learning and Petri Nets. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 56(8), 1120-1134. [14.] Barenji, A. V., & Montreuil, B. (2024). Edge-computing enabled multi-agent deep reinforcement learning for dynamic scheduling in hyperconnected manufacturing. Robotics and Computer-Integrated Manufacturing, 88, 102715. [15.] Zhang, L., & Zhou, Y. (2025). Distributed multi-agent reinforcement learning for energy-conscious dynamic scheduling in internet-of-things-enabled workshops. IEEE Internet of Things Journal, 12(4), 3120-3135.		

[16.] Karnik, M., & CP, CP. (2024). Decentralized dynamic scheduling using multi-agent deep Q-networks in cyber-physical production systems. *Journal of Intelligent Manufacturing*, 35(6), 2541-2559.

[17.] Pan, Z., & Dynamic, D. (2026). Real-time collaborative scheduling in cloud-edge manufacturing: A multi-agent deep reinforcement learning framework. *Advanced Engineering Informatics*, 60, 102410.

[18.] Nozari, H., & Yordanova, Z. (2026). Hierarchical Digital Twin Orchestration Across Edge and Cloud for Scalable Manufacturing Intelligence. *Algorithms*, 19(6), 450.

[19.] Liu, Q., Zhang, H., & CP, CP. (2025). Closed-Loop Digital Twin Framework for Energy-Efficient Optimization and Predictive Control in Manufacturing Continuum. *Information*, 17(2), 195.

[20.] Shao, G., & Helu, J. (2024). Digital Twin-based production scheduling using real-time edge analytics and model predictive feedback. *Journal of Manufacturing Systems*, 72, 112-126.

[21.] Leng, J., & Wang, D. (2023). Digital twin-driven smart manufacturing system scheduling using deep reinforcement learning: A case study of automated guided vehicles. *Journal of Manufacturing Systems*, 70, 412-425.

[22.] Wang, J., & CP, CP. (2026). Real-Time Feasibility of Digital Twins for Complex Model Predictive Process Control. *Processes*, 14(6), 595.

[23.] Ghaleb, M., Taghipour, S., & Zolfagharinia, H. (2021). Real-time integrated production-scheduling and maintenance-planning in a flexible job shop with machine deterioration and condition-based maintenance. *Journal of Manufacturing Systems*, 61, 423-449.

[24.] Park, I.-B., & Jhang, J. (2024). An adaptive rescheduling method using neural networks under sudden rush orders in flexible manufacturing. *International Journal of Advanced Manufacturing Technology*, 131(5), 2115-2130.

[25.] Xiong, H., & Dynamic, D. (2025). Deep reinforcement learning for dynamic scheduling with random job arrivals and multi-resource constraints. *European Journal of Operational Research*, 318(2), 485-501.

[26.] Sun, Y., & Continuous, C. (2026). Data-driven real-time rescheduling for smart workshops under continuous disruptions using transformers. *Computers in Industry*, 174, 104190.

[27.] Fraile, H.-J., & Process, P. (2025). Explainable AI (XAI) for human-in-the-loop dynamic rescheduling in cyber-physical production networks. *Control Engineering Practice*, 148, 105910.

9. Coroborarea conținuturilor disciplinei cu așteptările reprezentanților comunității epistemice, asociațiilor profesionale și angajatori reprezentativi din domeniul aferent programului

Conținuturile disciplinei sunt corelate cu direcțiile actuale de cercetare din domeniul Ingineriei sistemelor, privind utilizarea metodelor de Inteligență Artificială (AI) pentru planificarea și replanificarea dinamică a proceselor de producție. Tematica disciplinei abordează utilizarea Machine Learning, Deep Reinforcement Learning (DRL) și Multi-Agent Reinforcement Learning (MARL) pentru dezvoltarea unor strategii de Scheduling Dinamic capabile să răspundă modificărilor, perturbațiilor și incertitudinilor specifice sistemelor de producție inteligente. Conținuturile sunt corelate cu preocupările comunității științifice și profesionale reflectate în literatura internațională de specialitate, inclusiv în publicații IEEE și reviste internaționale din domeniul sistemelor de producție, automatizării și optimizării, privind DRL/MARL, Graph Neural Networks, metode evolutive și meta-euristice aplicate problemelor de Dynamic Scheduling. Conținuturile disciplinei răspund, de asemenea, cerințelor mediului economic și ale angajatorilor din domeniile automatizărilor industriale, sistemelor de producție inteligente, digitalizării și optimizării proceselor industriale, prin dezvoltarea capacității de analiză și evaluare a soluțiilor AI pentru planificarea și replanificarea proceselor în condiții de defectare a echipamentelor, sosire dinamică a comenzilor, constrângeri de resurse și alte perturbații ale sistemului de producție. Bibliografia include explicit abordări privind aceste situații și integrarea cerințelor de mentenanță în procesul de scheduling. Disciplina contribuie la fundamentarea unei cercetări doctorale privind Inteligența Artificială aplicată în Scheduling Dinamic, inclusiv prin integrarea metodelor AI cu Digital Twin și arhitecturile Cloud-Edge, creând premise pentru dezvoltarea unor soluții adaptive de planificare și replanificare în timp real, cu potențial de aplicare în sistemele de producție inteligente.

10. Evaluare

Tip activitate	10.1 Criterii de evaluare	10.2 Metode de evaluare	10.3 Pondere din nota finală
10.4 Colocviu	Corectitudinea și completitudinea cunoștințelor dobândite privind principiile și metodele de Inteligență Artificială (AI) aplicate în Scheduling Dinamic; capacitatea de identificare, selectare, analiză critică și sinteză a literaturii științifice de specialitate; capacitatea de analiză comparativă a metodelor de Machine Learning, Deep Reinforcement Learning (DRL), Multi-Agent Reinforcement Learning (MARL) și a altor abordări AI utilizate pentru planificarea și replanificarea dinamică; evaluarea soluțiilor AI din perspectiva capacității de adaptare la perturbații și incertitudini, a performanței producției, eficienței energetice, robusteții și adaptării în timp real; utilizarea adecvată a terminologiei științifice specifice domeniului; identificarea și argumentarea avantajelor, limitărilor și lacunelor soluțiilor existente; fundamentarea științifică a cadrului conceptual și metodologic și a direcției proprii de cercetare privind aplicarea Inteligenței Artificiale în	Colocviu oral și evaluarea raportului individual de studiu	100%

	Scheduling Dinamic.		
10.5 Proiect	-	-	-
10.6 Standard minim de performanță			
Pentru promovarea disciplinei, studentul trebuie să îndeplinească cumulativ următoarele condiții:			
Să obțină minimum 50% din punctajul aferent colocviului și să demonstreze atingerea rezultatelor învățării prin: - identificarea, selectarea și utilizarea adecvată a literaturii științifice relevante privind metodele de Inteligență Artificială (AI) aplicate în Scheduling Dinamic; - cunoașterea principiilor și metodelor de Machine Learning, Deep Reinforcement Learning (DRL) și Multi-Agent Reinforcement Learning (MARL) utilizate pentru planificarea și replanificarea dinamică a proceselor de producție; - realizarea unei analize critice și a unei sinteze bibliografice privind metodele AI pentru Scheduling Dinamic, fundamentată pe surse științifice actuale și relevante; - compararea și argumentarea adecvării soluțiilor AI pentru adaptarea procesului de scheduling la perturbări, incertitudini, defectarea echipamentelor, modificarea comenzilor și constrângerile de resurse; - identificarea avantajelor, limitărilor și lacunelor soluțiilor existente și fundamentarea cadrului conceptual și metodologic și a direcției proprii de cercetare privind aplicarea Inteligenței Artificiale în Scheduling Dinamic; - utilizarea corectă a terminologiei științifice și respectarea principiilor eticii și integrității academice în elaborarea și prezentarea raportului individual de studiu.			
Standardul minim de performanță validează atingerea rezultatelor învățării definite la pct. 7.			

Fișa disciplinei corespunde planului de învățământ care se aplică pentru anul I începând cu anul universitar 2027-2028.

Data completării

Titularul de curs (Conducator doctorat)
Prof. univ. dr. ing. Eugenia MINCĂ

Titularul de laborator

Data avizării în
CSD

Director SDSI
Prof. univ. dr. ing. Dinu COLȚUC

Data avizării în
CSUD

Director CSUD
Prof. univ. dr. ing. Rodica Mariana ION



Ministerul Educației și Cercetării
Universitatea „Valahia” din Târgoviște
Scoala Doctorală de Științe Inginerești

FIȘA DISCIPLINEI

1. Date despre program

1.1 Instituția de învățământ superior	Universitatea „Valahia” din Targoviște
1.2 Facultatea/Departamentul	Instituția Organizatoare de Studii Universitare de Doctorat
1.3 Departamentul	Școala Doctorală de Științe Inginerești
1.4 Domeniul de studii	Ingineria sistemelor
1.5 Ciclul de studii	Doctorat
1.6 Programul de studii/Calificarea	-

2. Date despre disciplină

2.1 Denumirea disciplinei	Studiu individual 3 (Arhitecturi Hibride Edge-Cloud pentru Agenți Industriali)						
2.2 Titularul activităților de curs / Conducător doctorat	Prof. univ. dr. ing. Eugenia MINCĂ						
2.3 Titularul activităților de seminar/laborator							
2.4 Anul de studiu	I	2.5 Semestrul	I	2.6 Tipul de evaluare	C	2.7 Regimul disciplinei	OB S

3. Timpul total estimat (ore pe semestru al activităților didactice)

3.1 Număr de ore pe săptămână	-	din care: 3.2 curs	-	3.3 seminar/laborator	-
3.4 Total ore din planul de învățământ	-	din care: 3.5 curs	-	3.6 seminar/laborator	-
Distribuția fondului de timp					Ore
Studiul după manual, suport de curs, bibliografie și notițe					-
Documentare suplimentară în bibliotecă, pe platformele electronice de specialitate și pe teren					145
- Studiul bibliografiei recomandate (manuale, monografii, articole ISI, standarde, baze de date) / 90h					
- Documentare suplimentară în biblioteci și baze de date științifice (Scopus, Web of Science, Springer, IEEE etc.) / 45h					
- Elaborarea sintezelor bibliografice, analizelor critice și portofoliului individual de studiu / 35h					
Pregătire seminarii/laboratoare, teme, referate, portofolii și eseuri					-
Tutoriat					20
Examinări (<i>pregătirea și susținerea colocviului</i>)					10
Alte activități					-
3.7 Total ore studiu individual					175
3.8 Total ore pe semestru					175
3.9 Numărul de credite					7

4. Precondiții (acolo unde este cazul)

4.1 de curriculum	
4.2 de competențe	

5. Condiții (acolo unde este cazul)

5.1 de desfășurare a cursului	
5.2 de desfășurare a seminarului/laboratorului	

6. Obiectivele disciplinei (reieșind din grila competențelor specifice acumulate)

6.1 Obiectivul general al disciplinei	Dezvoltarea capacității studentului-doctorand de a analiza critic și de a valorifica literatura științifică privind arhitecturile hibride Edge-Cloud pentru agenți industriali, în vederea evaluării mecanismelor de distribuire a funcțiilor de calcul, procesare și decizie, a soluțiilor de orchestrare și coordonare a agenților în sisteme industriale distribuite și a fundamentării cadrului conceptual și metodologic și a direcției proprii de cercetare doctorală în domeniul Ingineriei sistemelor.
6.2 Obiectivele specifice	- aprofundarea cunoștințelor privind conceptele, modelele și arhitecturile hibride Edge-Cloud pentru agenți industriali, cu accent pe distribuirea funcțiilor de calcul, procesare și decizie și pe organizarea sistemelor multi-agent în medii industriale distribuite; - dezvoltarea capacității de documentare științifică utilizând baze de date internaționale și surse bibliografice relevante privind arhitecturile Edge-Cloud, agenții industriali și sistemele multi-agent; - formarea competențelor de analiză critică, comparare și evaluare a metodelor de orchestrare, coordonare și distribuire a sarcinilor, incluzând task scheduling, computation offloading, load balancing și mecanisme de consens în infrastructuri Edge-Cloud; - aprofundarea metodelor de inteligență distribuită și coordonare adaptivă a agenților, inclusiv a soluțiilor bazate pe Deep Reinforcement Learning și Federated Reinforcement Learning, în raport cu cerințele sistemelor industriale distribuite; - identificarea tendințelor actuale, a avantajelor și limitărilor soluțiilor existente și a direcțiilor emergente privind arhitecturile Edge-Cloud pentru agenți industriali, din perspectiva latenței, scalabilității, interoperabilității, rezilienței și adaptării la condiții dinamice de funcționare; - dezvoltarea capacității de elaborare a unei sinteze bibliografice argumentate, de fundamentare a cadrului conceptual și metodologic și de definire a direcției proprii de cercetare doctorală privind arhitecturile hibride Edge-Cloud pentru agenți industriali.

7. Rezultatele învățării

7.1 Cunoștințe (<i>Rezultatul asimilării de informații prin învățare. Cunoștințele reprezintă ansamblul de fapte, principii, teorii și practici legate de un anumit domeniu de muncă sau de studiu. Pot fi teoretice și/sau faptice</i>)
La finalizarea disciplinei, studentul-doctorand/absolventul: - demonstrează cunoștințe avansate privind conceptele, modelele și arhitecturile hibride Edge-Cloud pentru agenți industriali, precum și distribuirea funcțiilor de calcul, procesare și decizie în sisteme industriale distribuite; - cunoaște principiile și mecanismele de orchestrare, coordonare și distribuire a sarcinilor agenților industriali, incluzând task scheduling, computation offloading, load balancing și mecanisme de consens; - înțelege principiile metodelor de inteligență distribuită și coordonare adaptivă a agenților, inclusiv utilizarea Deep Reinforcement Learning și Federated Reinforcement Learning în infrastructuri Edge-Cloud; - cunoaște cerințele și tendințele actuale privind proiectarea arhitecturilor Edge-Cloud pentru sisteme industriale distribuite, din perspectiva latenței, scalabilității, interoperabilității, rezilienței și adaptării la condiții dinamice de funcționare.
7.2 Aptitudini (<i>Capacitatea de a aplica cunoștințe și de a utiliza know-how pentru a duce la îndeplinire sarcini și a rezolva probleme. Aptitudinile sunt descrise ca fiind cognitive (implicând utilizarea gândirii logice, intuitive și creative) sau practice (implicând dexteritate manuală și utilizarea de metode, materiale, unelte și instrumente))</i>)
Studentul-doctorand /absolventul este capabil: - să identifice, selecteze și analizeze critic literatura științifică relevantă privind arhitecturile hibride Edge-Cloud și agenții industriali; - să analizeze comparativ diferite arhitecturi Edge-Cloud și să evalueze adecvarea acestora pentru distribuirea funcțiilor de calcul, procesare și decizie în sisteme industriale; - să compare și să evalueze metodele de orchestrare, coordonare și distribuire a sarcinilor agenților, în raport cu cerințele și constrângerile sistemului industrial analizat; - să analizeze critic metodele de inteligență distribuită și coordonare adaptivă a agenților și să evalueze adecvarea acestora în raport cu cerințele de latență, scalabilitate, interoperabilitate și reziliență; - să evalueze avantajele și limitările soluțiilor Edge-Cloud pentru agenți industriali și să identifice lacune și direcții emergente de cercetare; - să fundamenteze cadrul conceptual și metodologic și direcția proprie de cercetare privind arhitecturile hibride Edge-Cloud pentru agenți industriali.
7.3 Responsabilitate și autonomie (<i>Capacitatea cursantului de a aplica în mod autonom și responsabil cunoștințele și aptitudinile sale</i>)
Studentul-doctorand /absolventul: - desfășoară în mod autonom activități de documentare, analiză critică și sinteză privind arhitecturile hibride Edge-Cloud și agenții industriali, cu respectarea principiilor eticii și integrității academice; - își asumă responsabilitatea pentru selectarea și evaluarea critică a arhitecturilor și mecanismelor de orchestrare și coordonare relevante pentru problema de cercetare analizată; - argumentează în mod independent alegerea soluțiilor de distribuire a funcțiilor și resurselor între Edge și

- Cloud, în raport cu cerințele și constrângerile sistemului industrial;
dezvoltă în mod autonom cadrul conceptual și metodologic și își asumă responsabilitatea pentru fundamentarea științifică a direcției proprii de cercetare privind arhitecturile hibride Edge-Cloud pentru agenți industriali.

8. Conținuturi

8.2 Studiu individual	Metode de predare	Observații
Studierea bibliografiei fundamentale privind conceptele, modelele și arhitecturile hibride Edge-Cloud pentru agenți industriali, cu accent pe distribuirea funcțiilor de calcul, procesare și decizie între nivelurile Edge și Cloud, organizarea sistemelor multi-agent și rolul agenților inteligenți în sistemele cyber-fizice și mediile de producție inteligente.	Studiu individual, analiză bibliografică	45 h
Documentarea în baze de date științifice privind metodele și tehnologiile de orchestrare, coordonare și distribuire a sarcinilor agenților industriali în infrastructuri Edge-Cloud, cu accent pe task scheduling, computation offloading, load balancing, mecanisme de consens și gestionarea resurselor de calcul și comunicație în medii industriale distribuite.	Documentare în baze de date, analiză critică	25 h
Analiza critică și comparativă a literaturii privind arhitecturile și mecanismele de inteligență distribuită pentru agenți industriali, cu evaluarea soluțiilor bazate pe sisteme multi-agent, Deep Reinforcement Learning, Federated Reinforcement Learning și alte metode de coordonare inteligentă, din perspectiva latenței, scalabilității, interoperabilității, rezilienței și adaptării la condițiile dinamice de funcționare.	Analiză comparativă, sinteză bibliografică	25 h
Elaborarea unei sinteze bibliografice privind tendințele actuale și direcțiile emergente de cercetare referitoare la arhitecturile hibride Edge-Cloud pentru agenți industriali, cu identificarea avantajelor și limitărilor soluțiilor existente, a cerințelor privind orchestrarea și coordonarea agenților și fundamentarea cadrului conceptual și metodologic și a direcției proprii de cercetare doctorală.	Elaborare individuală, redactare academică	30 h
Consultări periodice cu titularul disciplinei și/sau conducătorul de doctorat privind bibliografia, direcțiile de cercetare și interpretarea critică a rezultatelor din literatura de specialitate.	Tutoriat, discuții individuale	20 h
Pregătirea și susținerea colocviului pe baza studiului individual și a raportului de documentare realizat.	Studiu individual, prezentare și susținere	30 h
Bibliografie		
[1.] Wang, J., Liu, X., & Zhang, Y. (2026). A survey of edge-cloud collaborative large language models and industrial agents for smart manufacturing systems. <i>Journal of Manufacturing Systems</i>, vol. 82, pp. 114-135. doi:10.1016/j.jmsy.2026.04.002. [2.] Chen, L., Wu, T., & Silva, J. (2026). Hybrid agentic AI and multi-agent systems in smart factories: Co-orchestration between cloud-level strategic LLMs and edge-level SLMs. <i>Journal of Manufacturing Systems</i>, vol. 84, pp. 241-258. doi:10.1016/j.jmapro.2026.02.015. [3.] Al-Saeed, M., Hassan, A., & Verma, P. (2026). Edge-Cloud Collaborative Framework for Real-Time Quality Control and Distributed Autonomous Agents in Smart Manufacturing. <i>Sensors</i>, vol. 26, nr. 7, art. no. 1941, pp. 1-24. doi:10.3390/s26071941. [4.] Kashani, A., Imbalzano, G., & Nguyen, K. T. (2026). Multi-Agent AI Systems for Autonomous and Context-Aware Data Orchestration in Hybrid Edge-Cloud Platforms. <i>Information Sciences</i>, vol. 689, pp. 115-132. doi:10.1016/j.ins.2026.01.074. [5.] Siddiqui, M. A., & Khan, S. (2026). Intelligent Edge-Cloud Collaborative Architectures for Smart Industrial Automation and Heterogeneous Agent Scheduling. <i>Journal of Industrial Information Integration</i>, vol. 44, pp. 100812-100829. doi:10.1016/j.jii.2026.03.007. [6.] Leitão, P., Barbosa, J., & Colombo, A. W. (2024). Adaptive intelligent agent for cloud-edge collaborative task identification and dynamic load balancing in industrial CPS. <i>Journal of King Saud University - Computer and Information Sciences</i>, vol. 36, nr. 10, pp. 101-118. doi:10.1016/j.jksuci.2024.102190. [7.] Gao, R., Xu, Y., & Tong, X. (2025). A Reconfigurable Method for Intelligent Manufacturing Based on Industrial Cloud and Edge Intelligence for Multi-Agent Collaborative Networks. <i>IEEE Transactions on Industrial Informatics</i>, vol. 21, nr. 4, pp. 3845-3856. doi:10.1109/TII.2025.3396085. [8.] Rodriguez, A., Martínez, L., & García, F. (2025). Graph-Aware Task Scheduling for Multi-Agent Workflows in Heterogeneous Edge-Cloud Environments. <i>Future Internet</i>, vol. 18, nr. 5, art. no. 265, pp. 1-21. doi:10.3390/fi18050265. [9.] Bécue, A., Praça, I., & Sousa, J. (2024). A multi-agent architecture for edge-cloud collaborative security monitoring in smart manufacturing. <i>Computers in Industry</i>, vol. 156, pp. 104085-104101. doi:10.1016/j.compind.2024.104085. [10.] Vrba, P., Radakovic, M., & Marik, V. (2023). Industrial Agents in the Cloud-Edge Continuum: A Review of Architectural Patterns and Deployment Strategies. <i>IEEE Transactions on Industrial Informatics</i>, vol. 19, nr. 8, pp. 8945-8958. doi:10.1109/TII.2022.3221450. [11.] Karnouskos, S., & Colombo, A. W. (2024). Architecting Next-Generation Cyber-Physical Production Systems: The Role of Edge-Cloud Agent Orchestration. <i>Annual Reviews in Control</i>, vol. 57, pp. 100912-100927. doi:10.1016/j.arcontrol.2024.100912 [12.] Li, X., Wang, Z., & Harrison, R. (2024). Dynamic computation offloading for autonomous industrial agents in		

- multi-access edge computing environment. *Journal of Manufacturing Systems*, vol. 74, pp. 412-427. doi:10.1016/j.jmsy.2024.03.011.
- [13.] Zhang, L., Shao, Y., & Cheng, Y. (2025). Deep reinforcement learning for agent-based low-latency task orchestration in hybrid cloud-edge networks. *Scientific Reports*, vol. 15, nr. 1, art. no. 5412, pp. 1-16. doi:10.1038/s41598-025-89412-x.
- [14.] Nguyen, T. H., & Zhang, Y. (2025). Distributed consensus algorithms for heterogeneous industrial agents across edge-cloud boundaries. *Information Sciences*, vol. 694, pp. 210-228. doi:10.1016/j.ins.2024.12.045.
- [15.] Zheng, P., & Wang, Z. (2024). Edge-Cloud collaborative intelligence for industrial robots: Real-time trajectory optimization and high-level reasoning agents. *Robotics and Computer-Integrated Manufacturing*, vol. 89, pp. 102750-102765. doi:10.1016/j.rcim.2024.102750.
- [16.] Müller, T., & Schmidt, M. (2025). Time-sensitive agent coordination in discrete-event manufacturing systems using hybrid edge-cloud infrastructures. *Journal of Process Control*, vol. 136, pp. 45-58. doi:10.1016/j.jprocont.2025.01.004.
- [17.] Choi, S., & Kim, H. (2024). A Kubernetes-based multi-agent orchestration framework for cloud-edge collaborative industrial applications. *IEEE Open Journal of the Industrial Electronics Society*, vol. 5, pp. 182-195. doi:10.1109/OJIES.2024.3361204.
- [18.] Singamsetty, S., & Kumar, A. (2026). Federated reinforcement learning for distributed agents in cloud-edge industrial IoT frameworks. *IEEE Internet of Things Journal*, vol. 14, nr. 2, pp. 2042-2057. doi:10.1109/JIOT.2025.3510294.
- [19.] Hasan, M. M., & Yu, J. (2024). Edge-assisted active learning agents for predictive maintenance optimization in cloud-centric networks. *Reliability Engineering & System Safety*, vol. 248, pp. 110120-110138. doi:10.1016/j.ress.2024.110120.
- [20.] Martinez, E., & Silva, R. (2025). Cross-layer agent-driven data reduction and streaming optimization in industrial edge-cloud systems. *IEEE Transactions on Industrial Cyber-Physical Systems*, vol. 3, pp. 88-103. doi:10.1109/TICPS.2024.3411025.
- [21.] Zhou, Y., & Gao, R. (2024). Decentralized edge agents with cloud-guided distillation for vision-based industrial quality control. *IEEE Transactions on Automation Science and Engineering*, vol. 21, nr. 4, pp. 3120-3135. doi:10.1109/TASE.2023.3321458.
- [22.] Garg, N., & Sharma, S. (2025). Resilient multi-agent task execution in hybrid cloud-edge topologies under communication constraints. *Journal of Network and Computer Applications*, vol. 235, pp. 103850-103868. doi:10.1016/j.jnca.2024.103850.
- [23.] Zhao, L., & Feng, Y. (2025). An event-driven edge agent architecture for dynamic manufacturing scheduling using predictive cloud insights. *International Journal of Production Economics*, vol. 280, pp. 109210-109226. doi:10.1016/j.ijpe.2024.109210.
- [24.] Anderl, R., & Lanza, G. (2024). Interoperable cloud-edge architectures for agent-based zero-defect manufacturing lines. *CIRP Annals*, vol. 73, nr. 1, pp. 153-156. doi:10.1016/j.cirp.2024.04.015.
- [25.] Puttonen, J., & Lobov, A. (2023). Containerized edge-cloud agents for agile product routing in reconfigurable assembly systems. *Computers & Industrial Engineering*, vol. 185, pp. 109640-109655. doi:10.1016/j.cie.2023.109640.

9. Coroborarea conținuturilor disciplinei cu așteptările reprezentanților comunității epistemice, asociațiilor profesionale și angajatori reprezentativi din domeniul aferent programului

Conținuturile disciplinei sunt corelate cu direcțiile actuale de cercetare din domeniul Ingineriei sistemelor, privind dezvoltarea arhitecturilor hibride Edge-Cloud, a sistemelor multi-agent și a mecanismelor de distribuire a funcțiilor de calcul, procesare și decizie în sisteme industriale inteligente și distribuite. Tematica disciplinei abordează orchestrarea și coordonarea agenților industriali, distribuirea sarcinilor și resurselor și integrarea inteligenței distribuite, direcții reflectate în literatura științifică internațională inclusă în bibliografie. Conținuturile sunt corelate cu preocupările comunității științifice și profesionale privind task scheduling, computation offloading, load balancing, consensul distribuit și coordonarea adaptivă a agenților, precum și utilizarea metodelor de inteligență artificială distribuită în infrastructuri Edge-Cloud. Sunt avute în vedere cerințe relevante pentru sistemele industriale complexe, precum latența, scalabilitatea, interoperabilitatea, reziliența și adaptarea la condiții dinamice de funcționare. Disciplina răspunde, de asemenea, cerințelor mediului industrial privind dezvoltarea unor sisteme cyber-fizice și de producție inteligente, distribuite și reconfigurabile, capabile să asigure coordonarea agenților și utilizarea eficientă a resurselor de calcul și comunicație. Aplicațiile abordate în bibliografie includ automatizarea industrială, controlul calității, mentenanța predictivă, scheduling-ul dinamic, robotica industrială și sistemele de producție reconfigurabile. Disciplina contribuie astfel la fundamentarea cercetării doctorale în Ingineria sistemelor și la dezvoltarea capacității de analiză, evaluare și selectare a arhitecturilor și mecanismelor de coordonare adecvate sistemelor industriale distribuite, creând premise pentru dezvoltarea ulterioară a unor arhitecturi și soluții originale Edge-Cloud pentru agenți industriali, cu potențial de valorificare în mediul industrial.

10. Evaluare

Tip activitate	10.1 Criterii de evaluare	10.2 Metode de evaluare	10.3 Pondere din nota finală
10.4 Colocviu	Corectitudinea și completitudinea cunoștințelor dobândite privind conceptele, modelele și arhitecturile hibride Edge-Cloud pentru agenți industriali; capacitatea de identificare, selectare, analiză critică și sinteză a literaturii științifice de specialitate; capacitatea de analiză comparativă și evaluare a mecanismelor de orchestrare, coordonare și distribuire a sarcinilor și resurselor între Edge și Cloud; evaluarea critică a metodelor de inteligență distribuită și coordonare adaptivă a agenților în raport cu cerințele sistemelor industriale privind latența, scalabilitatea, interoperabilitatea, reziliența și adaptabilitatea; utilizarea adecvată a terminologiei științifice specifice domeniului; identificarea și argumentarea avantajelor, limitărilor și lacunelor soluțiilor existente; fundamentarea științifică a cadrului conceptual și metodologic și a direcției proprii de cercetare privind arhitecturile hibride Edge-Cloud pentru agenți industriali.	Colocviu oral și evaluarea raportului individual de studiu	100%
10.5 Proiect	-	-	-
10.6 Standard minim de performanță			
Pentru promovarea disciplinei, studentul trebuie să îndeplinească cumulativ următoarele condiții:			
Să obțină minimum 50% din punctajul aferent colocviului și să demonstreze atingerea rezultatelor învățării prin: - identificarea, selectarea și utilizarea adecvată a literaturii științifice relevante privind arhitecturile hibride Edge-Cloud pentru agenți industriali; - cunoașterea conceptelor, modelelor și principiilor privind distribuirea funcțiilor de calcul, procesare și decizie între nivelurile Edge și Cloud și organizarea sistemelor multi-agent; - realizarea unei analize critice și a unei sinteze bibliografice privind mecanismele de orchestrare, coordonare și distribuire a sarcinilor și resurselor în sisteme industriale distribuite; - compararea și argumentarea adecvării arhitecturilor și mecanismelor de coordonare a agenților în raport cu cerințele privind latența, scalabilitatea, interoperabilitatea, reziliența și adaptarea la condiții dinamice de funcționare; - identificarea avantajelor, limitărilor și lacunelor soluțiilor existente și fundamentarea cadrului conceptual și metodologic și a direcției proprii de cercetare privind arhitecturile hibride Edge-Cloud pentru agenți industriali; - utilizarea corectă a terminologiei științifice și respectarea principiilor eticii și integrității academice în elaborarea și prezentarea raportului individual de studiu.			
Standardul minim de performanță validează atingerea rezultatelor învățării definite la pct. 7.			

Fișa disciplinei corespunde planului de învățământ care se aplică pentru anul I începând cu anul universitar 2027-2028.

Data completării

Titularul de curs (Conducator doctorat)
Prof. univ. dr. ing. Eugenia MINCĂ

Titularul de laborator

Data avizării în
CSD

Director SDSI
Prof. univ. dr. ing. Dinu COLȚUC

Data avizării în
CSUD

Director CSUD
Prof. univ. dr. ing. Rodica Mariana ION



Ministerul Educației și Cercetării
Universitatea „Valahia” din Târgoviște
Scoala Doctorală de Științe Inginerești

FIȘA DISCIPLINEI

1. Date despre program

1.1 Instituția de învățământ superior	Universitatea „Valahia” din Targoviște
1.2 Facultatea/Departamentul	Instituția Organizatoare de Studii Universitare de Doctorat
1.3 Departamentul	Școala Doctorală de Științe Inginerești
1.4 Domeniul de studii	Ingineria sistemelor
1.5 Ciclu de studii	Doctorat
1.6 Programul de studii/Calificarea	-

2. Date despre disciplină

2.1 Denumirea disciplinei	Studiu individual 3 (Interoperabilitatea sistemelor de management energetic cu platforme multi-vendor (Victron, Fronius, Huawei))						
2.2 Titularul activităților de curs / Conducător doctorat	Prof. univ. dr. ing. Florin DRAGOMIR						
2.3 Titularul activităților de seminar/laborator							
2.4 Anul de studiu	I	2.5 Semestrul	I	2.6 Tipul de evaluare	C	2.7 Regimul disciplinei	OB S

3. Timpul total estimat (ore pe semestru al activităților didactice)

3.1 Număr de ore pe săptămână	-	din care: 3.2 curs	-	3.3 seminar/laborator	-
3.4 Total ore din planul de învățământ	-	din care: 3.5 curs	-	3.6 seminar/laborator	-
Distribuția fondului de timp					Ore
Studiul după manual, suport de curs, bibliografie și notițe					-
Documentare suplimentară în bibliotecă, pe platformele electronice de specialitate și pe teren					145
- Studiul bibliografiei recomandate (manuale, monografii, articole ISI, standarde, baze de date) / 90h					
- Documentare suplimentară în biblioteci și baze de date științifice (Scopus, Web of Science, Springer, IEEE etc.) / 45h					
- Elaborarea sintezelor bibliografice, analizelor critice și portofoliului individual de studiu / 35h					
Pregătire seminarii/laboratoare, teme, referate, portofolii și eseuri					-
Tutoriat					20
Examinări (pregătirea și susținerea colocviului)					10
Alte activități					-
3.7 Total ore studiu individual					175
3.8 Total ore pe semestru					175
3.9 Numărul de credite					7

4. Precondiții (acolo unde este cazul)

4.1 de curriculum	
4.2 de competențe	

5. Condiții (acolo unde este cazul)

5.1 de desfășurare a cursului	
5.2 de desfășurare a seminarului/laboratorului	

6. Obiectivele disciplinei (reieșind din grila competențelor specifice acumulate)

6.1 Obiectivul general al disciplinei	Dezvoltarea capacității studentului-doctorand de a analiza critic și de a valorifica literatura științifică, standardele și documentațiile tehnice privind arhitecturile și interoperabilitatea sistemelor de management energetic multi-vendor, cu particularizări pentru platformele Victron, Fronius și Huawei, în vederea identificării cerințelor și limitărilor de integrare, fundamentării cadrului conceptual și metodologic și definirii direcției proprii de cercetare doctorală privind coordonarea și integrarea sistemelor energetice eterogene în domeniul Ingineriei sistemelor.
6.2 Obiectivele specifice	- aprofundarea cunoștințelor privind arhitecturile și principiile de funcționare ale sistemelor de management energetic pentru microrețele și sisteme energetice distribuite, cu accent pe integrarea echipamentelor și subsistemelor provenite de la producători diferiți; - dezvoltarea capacității de documentare științifică și tehnică privind platformele Victron, Fronius și Huawei, standardele, protocoalele de comunicație și interfețele utilizate pentru schimbul de date, monitorizarea și controlul sistemelor energetice multi-vendor; - formarea competențelor de analiză critică și comparativă a soluțiilor de interoperabilitate, prin evaluarea compatibilității funcționale și informaționale, a mecanismelor de schimb de date și comenzi și a posibilităților de coordonare între subsisteme eterogene; - aprofundarea metodelor și arhitecturilor de integrare a surselor fotovoltaice, sistemelor de stocare, vehiculelor electrice și echipamentelor de conversie și control în cadrul unor sisteme de management energetic multi-vendor; - identificarea limitărilor arhitecturilor proprietare, a problemelor de interoperabilitate și a direcțiilor actuale de dezvoltare a arhitecturilor deschise de management energetic, precum și analiza metodelor de verificare și validare prin simulare și Hardware-in-the-Loop (HIL); - dezvoltarea capacității de elaborare a unei sinteze bibliografice argumentate, de fundamentare a cadrului conceptual și metodologic și de definire a direcției proprii de cercetare doctorală privind interoperabilitatea și integrarea sistemelor de management energetic multi-vendor.

7. Rezultatele învățării

7.1 Cunoștințe (<i>Rezultatul asimilării de informații prin învățare. Cunoștințele reprezintă ansamblul de fapte, principii, teorii și practici legate de un anumit domeniu de muncă sau de studiu. Pot fi teoretice și/sau faptice</i>)	La finalizarea disciplinei, studentul-doctorand/absolventul: - demonstrează cunoștințe avansate privind arhitecturile și principiile de funcționare ale sistemelor de management energetic pentru microrețele și sisteme energetice distribuite; - cunoaște principiile interoperabilității sistemelor energetice multi-vendor, standardele, protocoalele de comunicație și interfețele utilizate pentru schimbul de date, monitorizare și control; - cunoaște particularitățile arhitecturilor și mecanismelor de integrare specifice platformelor Victron, Fronius și Huawei, precum și posibilitățile de coordonare a echipamentelor și subsistemelor eterogene; - înțelege principiile și metodele de integrare și validare a sistemelor de management energetic multi-vendor, inclusiv utilizarea simulării și a tehnicilor Hardware-in-the-Loop (HIL).
7.2 Aptitudini (<i>Capacitatea de a aplica cunoștințe și de a utiliza know-how pentru a duce la îndeplinire sarcini și a rezolva probleme. Aptitudinile sunt descrise ca fiind cognitive (implicând utilizarea gândirii logice, intuitive și creative) sau practice (implicând dexteritate manuală și utilizarea de metode, materiale, unelte și instrumente)</i>)	Studentul-doctorand /absolventul este capabil: - demonstrează cunoștințe avansate privind arhitecturile și principiile de funcționare ale sistemelor de management energetic pentru microrețele și sisteme energetice distribuite; - cunoaște principiile interoperabilității sistemelor energetice multi-vendor, standardele, protocoalele de comunicație și interfețele utilizate pentru schimbul de date, monitorizare și control; - cunoaște particularitățile arhitecturilor și mecanismelor de integrare specifice platformelor Victron, Fronius și Huawei, precum și posibilitățile de coordonare a echipamentelor și subsistemelor eterogene; - înțelege principiile și metodele de integrare și validare a sistemelor de management energetic multi-vendor, inclusiv utilizarea simulării și a tehnicilor Hardware-in-the-Loop (HIL).
7.3 Responsabilitate și autonomie (<i>Capacitatea cursantului de a aplica în mod autonom și responsabil cunoștințele și aptitudinile sale</i>)	Studentul-doctorand /absolventul: - desfășoară în mod autonom activități de documentare, analiză critică și sinteză a literaturii științifice, standardelor și documentațiilor tehnice privind interoperabilitatea sistemelor energetice multi-vendor, cu respectarea principiilor eticii și integrității academice; - își asumă responsabilitatea pentru selectarea, evaluarea și fundamentarea soluțiilor de interoperabilitate și integrare adecvate obiectivelor cercetării doctorale; - argumentează în mod independent alegerea arhitecturilor, protocoalelor, interfețelor și metodelor de integrare și validare pentru sisteme de management energetic multi-vendor; - dezvoltă în mod autonom cadrul conceptual și metodologic al cercetării și își asumă responsabilitatea pentru

8. Conținuturi

8.2 Studiu individual	Metode de predare	Observații
Studiarea bibliografiei fundamentale privind arhitecturile și principiile de funcționare ale sistemelor de management energetic pentru microrțele și sisteme distribuite de energie, cu accent pe integrarea coordonată a surselor fotovoltaice, sistemelor de stocare, vehiculelor electrice și echipamentelor de conversie și control provenite de la producători diferiți.	Studiu individual, analiză bibliografică	45 h
Documentarea în baze de date științifice și în documentațiile tehnice de specialitate privind interoperabilitatea platformelor de management energetic multi-vendor, cu particularizare pentru ecosistemele Victron, Fronius și Huawei, incluzând arhitecturile de comunicație, protocoalele și interfețele de schimb de date, mecanismele de monitorizare și control și modalitățile de integrare într-un sistem energetic unitar.	Documentare în baze de date, analiză critică	25 h
Analiza critică și comparativă a literaturii și documentațiilor tehnice privind integrarea și interoperabilitatea platformelor Victron, Fronius și Huawei, cu evaluarea compatibilității funcționale și informaționale, a mecanismelor de schimb de date și comenzi, a posibilităților de coordonare a subsistemelor și a limitărilor asociate arhitecturilor proprietate și multi-vendor.	Analiză comparativă, sinteză bibliografică	25 h
Elaborarea unei sinteze bibliografice privind soluțiile actuale și direcțiile emergente pentru interoperabilitatea sistemelor de management energetic multi-vendor, cu identificarea cerințelor de integrare, a limitărilor soluțiilor existente, a posibilităților de validare prin simulare și Hardware-in-the-Loop și a direcțiilor relevante pentru fundamentarea cadrului conceptual și metodologic al cercetării doctorale.	Elaborare individuală, redactare academică	30 h
Consultări periodice cu titularul disciplinei și/sau conducătorul de doctorat privind bibliografia, direcțiile de cercetare și interpretarea critică a rezultatelor din literatura de specialitate.	Tutoriat, discuții individuale	20 h
Pregătirea și susținerea colocviului pe baza studiului individual și a raportului de documentare realizat.	Studiu individual, prezentare și susținere	30 h
Bibliografie [1.] Salaorni, D., Bianchi, F., Restelli, M., & Trovò, F. (2025). A reinforcement learning approach for optimal control in microgrids. arXiv preprint arXiv:2506.22995. https://doi.org/10.48550/arXiv.2506.22995 [2.] Burgaud, V., Laraki, M. H., Bossard, J., & Ploix, S. (2026). Reinforcement learning vs. model-based control in electric vehicle charging microgrids. Control Engineering Practice, 168, 106421. https://doi.org/10.1016/j.conengprac.2026.106421 [3.] Alshammari, N. F., Alshahr, S., & Barakat, S. (2026). How energy management strategy shapes optimal microgrid design: A comparative analysis for EV charging stations. Applied Energy, 381, 124982. https://doi.org/10.1016/j.apenergy.2026.124982 [4.] Maran, D., Salaorni, D., & Restelli, M. (2025). Reinforcement learning-based energy management in community microgrids: A comparative study. Sustainability, 17(23), 10696. https://doi.org/10.3390/su172310696 [5.] Rosero, D. G., Sanabria, E., Díaz, N. L., Trujillo, C. L., Luna, A., & Andrade, F. (2023). Full-deployed energy management system tested in a microgrid cluster. Applied Energy, 334, 120674. https://doi.org/10.1016/j.apenergy.2023.120674 [6.] Liu, Y., Wu, D., & Gao, S. (2024). Resilient control of networked microgrids using vertical federated reinforcement learning: Designs and real-time test-bed validations. IEEE Transactions on Industry Applications, 60(5), 6214-6225. https://doi.org/10.1109/TIA.2024.3384480 [7.] Wang, R., & Smart, G. (2024). Reinforcement learning in microgrid energy management: Review, methods and prospects. IET Smart Grid, 7(4), 412-431. https://doi.org/10.1049/stg2.70097 [8.] Sultanuddin, S. J., Vibin, R., & Pasha, M. J. (2024). Intelligent energy management system for microgrids using reinforcement learning. ResearchGate Tech Reports, 24(2), 115-128. https://doi.org/10.13140/RG.2.2.31422.56641 [9.] Wang, Z., Zhang, J., & Che, L. (2024). Deep reinforcement learning based optimal energy management of multi-energy microgrids with uncertainties. IEEE Transactions on Smart Grid, 15(4), 3912-3925. https://doi.org/10.1109/TSG.2024.10609308 [10.] Fauziah, K., Munir, B. S., Sriyono, S., & Anwar, S. (2024). Design and experimental validation of a cluster-based virtual power plant with centralized management system in compliance with IEC standard. Energies, 18(19), 5300. https://doi.org/10.3390/en18195300 [11.] Cho, I. S., & Kim, R. Y. (2023). Development of photovoltaic (PV) evaluation and fault detection system using hardware-in-the-loop simulation for PV applications. Electronics, 14(3), 674. https://doi.org/10.3390/electronics14030674 [12.] Alshahr, S., Barakat, S., & Alshammari, N. F. (2025). Hybrid supercapacitor-battery system for PV modules under partial shading: Modeling, simulation, and implementation. Energies, 18(23), 6110. https://doi.org/10.3390/en18236110 [13.] Rosero, D. G., Díaz, N. L., Trujillo, C. L., & Guerrero, J. M. (2018). Hardware-in-the-loop validation of energy		

management systems for microgrids: A short overview and a case study. *Energies*, 11(11), 2978. <https://doi.org/10.3390/en11112978>

[14.] Luna, A. C., Diaz, N. L., Andrade, F., Graells, M., & Guerrero, J. M. (2020). Hardware in the loop platform for testing photovoltaic system control. *Applied Sciences*, 10(23), 8690. <https://doi.org/10.3390/app10238690>

[15.] Yang, Z., Wang, S., Deng, J., Peng, X., Jiang, N., & Li, Y. (2024). Intelligent energy management method of EV charging station with photovoltaic and energy storage system considering EV charging scheduling. In *Proceedings of the 2024 8th International Conference on Power Energy Systems and Applications (ICoPESA)* (pp. 488-494). IEEE. <https://doi.org/10.1109/ICoPESA60932.2024.10543211>

[16.] Ucer, E., & Kisacikoglu, M. J. (2024). Development of a hardware-in-the-loop testbed for a decentralized, data-driven electric vehicle charging control algorithm. *IEEE Transactions on Industry Applications*, 60(4), 5234-5245. <https://doi.org/10.1109/TIA.2024.3384480>

[17.] Antoun, J., Assi, C., Atallah, R., & Moussa, B. (2023). A real world technology testbed for electric vehicle smart charging systems and PEV-EVSE interoperability evaluation. *IEEE Access*, 11, 125664-125683. <https://doi.org/10.1109/ACCESS.2023.3274608>

[18.] Kumar, R., Kaur, R., & Channi, H. K. (2025). Artificial intelligence integration in solar-powered EV charging systems: challenges, opportunities, and future perspectives. *Journal of Thermal Analysis and Calorimetry*, 150(2), 1610-1627. <https://doi.org/10.1007/s10973-025-14489-x>

[19.] Cavus, M., Ayan, H., Bell, M., & Dissanayake, D. (2026). Transitioning toward efficient smart charging of electric vehicles: Challenges and perspectives. *Engineering Management*, 34(1), e70088. <https://doi.org/10.1007/s42452-025-07529-6>

[20.] Rajesh, P. K., Soundarya, T., & Jithin, K. V. (2024). Integration of renewable resources in electric vehicle charging management systems using deep learning for monitoring and optimization. *Iranian Journal of Science and Technology, Transactions of Electrical Engineering*, 48(3), 583-596. <https://doi.org/10.1007/s40998-024-00720-y>

[21.] Selvam, K., Dhiman, H. S., Pandya, D., & Sahoo, S. (2025). Hardware-in-loop implementation of an adaptive MPPT controlled PV-assisted EV charging system with vehicle-to-grid integration. *Scientific Reports*, 15(1), 11442. <https://doi.org/10.1038/s41598-025-23446-x>

[22.] Documentații tehnice oficiale Victron, Fronius și Huawei; standarde și protocoale relevante pentru interoperabilitatea sistemelor energetice; lucrări științifice dedicate integrării multi-vendor și arhitecturilor deschise de EMS.

9. Coroborarea conținuturilor disciplinei cu așteptările reprezentanților comunității epistemice, asociațiilor profesionale și angajatori reprezentativi din domeniul aferent programului

Conținuturile disciplinei sunt corelate cu direcțiile actuale de cercetare și dezvoltare din domeniul Ingineriei sistemelor, privind integrarea, interoperabilitatea și coordonarea sistemelor complexe și distribuite, cu particularizare pentru sistemele de management energetic și microrețelele care integrează echipamente și subsisteme provenite de la producători diferiți. Tematica disciplinei abordează arhitecturile EMS, standardele și protocoalele de comunicație, interfețele de schimb de date și mecanismele de monitorizare și control necesare realizării unor sisteme energetice multi-vendor interoperabile. Conținuturile sunt corelate cu preocupările comunității științifice și profesionale privind dezvoltarea sistemelor energetice inteligente, integrarea surselor regenerabile, sistemelor de stocare și vehiculelor electrice, interoperabilitatea echipamentelor și validarea soluțiilor de management și control prin simulare și Hardware-in-the-Loop (HIL). Literatura de specialitate include lucrări privind implementarea și validarea sistemelor de management energetic, controlul microrețelelor și evaluarea interoperabilității în sisteme reale și experimentale. Disciplina răspunde, de asemenea, cerințelor mediului economic și ale angajatorilor din domeniile sistemelor energetice inteligente, automatizărilor, surselor regenerabile, stocării energiei, mobilității electrice și integrării sistemelor, prin dezvoltarea capacității de analiză, evaluare și fundamentare a soluțiilor de interoperabilitate între platforme și echipamente eterogene. Prin utilizarea documentațiilor tehnice oficiale Victron, Fronius și Huawei, a standardelor și protocoalelor relevante și a literaturii privind integrarea multi-vendor și arhitecturile deschise de EMS, disciplina asigură corelarea pregătirii doctorale cu cerințele tehnologice asociate integrării unor sisteme energetice reale. Disciplina contribuie astfel la fundamentarea unei cercetări doctorale orientate către dezvoltarea și validarea unor soluții interoperabile pentru integrarea și coordonarea sistemelor de management energetic multi-vendor.

10. Evaluare

Tip activitate	10.1 Criterii de evaluare	10.2 Metode de evaluare	10.3 Pondere din nota finală
10.4 Colocviu	Corectitudinea și completitudinea cunoștințelor dobândite privind arhitecturile și interoperabilitatea sistemelor de management energetic multi-vendor; capacitatea de identificare, selectare, analiză critică și sinteză a literaturii științifice, standardelor și documentațiilor tehnice de specialitate; capacitatea de analiză comparativă a arhitecturilor, protocoalelor și interfețelor de comunicație utilizate pentru integrarea platformelor Victron, Fronius și Huawei; evaluarea compatibilității funcționale și informaționale, a mecanismelor de schimb de date și	Colocviu oral și evaluarea raportului individual de studiu	100%

	comenzi și a posibilităților de coordonare a subsistemelor eterogene; identificarea și argumentarea limitărilor soluțiilor existente și a cerințelor de interoperabilitate; fundamentarea științifică a cadrului conceptual și metodologic și a direcției proprii de cercetare privind interoperabilitatea sistemelor de management energetic multi-vendor.		
10.5 Proiect	-	-	-
10.6 Standard minim de performanță			
Pentru promovarea disciplinei, studentul trebuie să îndeplinească cumulativ următoarele condiții:			
Să obțină minimum 50% din punctajul aferent colocviului și să demonstreze atingerea rezultatelor învățării prin: - identificarea, selectarea și utilizarea adecvată a literaturii științifice, standardelor și documentațiilor tehnice relevante privind interoperabilitatea sistemelor de management energetic multi-vendor; - cunoașterea principiilor, arhitecturilor, protocoalelor și interfețelor utilizate pentru integrarea, monitorizarea și controlul sistemelor energetice eterogene; - realizarea unei analize critice și comparative privind interoperabilitatea platformelor Victron, Fronius și Huawei, inclusiv compatibilitatea funcțională și informațională și mecanismele de schimb de date și comenzi; - identificarea și argumentarea cerințelor de integrare, a limitărilor soluțiilor existente și a problemelor de interoperabilitate specifice arhitecturilor multi-vendor; - fundamentarea cadrului conceptual și metodologic și a direcției proprii de cercetare privind interoperabilitatea sistemelor de management energetic multi-vendor; - utilizarea corectă a terminologiei științifice și tehnice și respectarea principiilor eticii și integrității academice în elaborarea și prezentarea raportului individual de studiu.			
Standardul minim de performanță validează atingerea rezultatelor învățării definite la pct. 7.			

Fișa disciplinei corespunde planului de învățământ care se aplică pentru anul I începând cu anul universitar 2027-2028.

Data completării

Titularul de curs (Conducator doctorat)
Prof. univ. dr. ing. Florin DRAGOMIR

Titularul de laborator

Data avizării în
CSD

Director SDSI
Prof. univ. dr. ing. Dinu COLȚUC

Data avizării în
CSUD

Director CSUD
Prof. univ. dr. ing. Rodica Mariana ION



Ministerul Educației și Cercetării
Universitatea „Valahia” din Târgoviște
Scoala Doctorală de Științe Inginerești

FIȘA DISCIPLINEI

1. Date despre program

1.1 Instituția de învățământ superior	Universitatea „Valahia” din Targoviște
1.2 Facultatea/Departamentul	Instituția Organizatoare de Studii Universitare de Doctorat
1.3 Departamentul	Școala Doctorală de Științe Inginerești
1.4 Domeniul de studii	Ingineria sistemelor
1.5 Ciclu de studii	Doctorat
1.6 Programul de studii/Calificarea	-

2. Date despre disciplină

2.1 Denumirea disciplinei	Studiu individual 3 (Validarea HIL (Hardware-in-the-Loop) a algoritmului MARL și analiza stabilității dinamice la joncțiunea cu PCC)						
2.2 Titularul activităților de curs / Conducător doctorat	Prof. univ. dr. ing. Florin DRAGOMIR						
2.3 Titularul activităților de seminar/laborator							
2.4 Anul de studiu	I	2.5 Semestrul	I	2.6 Tipul de evaluare	C	2.7 Regimul disciplinei	OB S

3. Timpul total estimat (ore pe semestru al activităților didactice)

3.1 Număr de ore pe săptămână	-	din care: 3.2 curs	-	3.3 seminar/laborator	-
3.4 Total ore din planul de învățământ	-	din care: 3.5 curs	-	3.6 seminar/laborator	-
Distribuția fondului de timp					Ore
Studiul după manual, suport de curs, bibliografie și notițe					-
Documentare suplimentară în bibliotecă, pe platformele electronice de specialitate și pe teren					145
- Studiul bibliografiei recomandate (manuale, monografii, articole ISI, standarde, baze de date) / 90h					
- Documentare suplimentară în biblioteci și baze de date științifice (Scopus, Web of Science, Springer, IEEE etc.) / 45h					
- Elaborarea sintezelor bibliografice, analizelor critice și portofoliului individual de studiu / 35h					
Pregătire seminarii/laboratoare, teme, referate, portofolii și eseuri					-
Tutoriat					20
Examinări (pregătirea și susținerea colocviului)					10
Alte activități					-
3.7 Total ore studiu individual					175
3.8 Total ore pe semestru					175
3.9 Numărul de credite					7

4. Precondiții (acolo unde este cazul)

4.1 de curriculum	
4.2 de competențe	

5. Condiții (acolo unde este cazul)

5.1 de desfășurare a cursului	
5.2 de desfășurare a seminarului/laboratorului	

6. Obiectivele disciplinei (reieșind din grila competențelor specifice acumulate)

6.1 Obiectivul general al disciplinei	Dezvoltarea capacității studentului-doctorand de a analiza critic și de a valorifica literatura științifică privind metodele și arhitecturile Hardware-in-the-Loop (HIL) pentru validarea în timp real a algoritmilor Multi-Agent Reinforcement Learning (MARL) și evaluarea stabilității dinamice a microgridurilor conectate la rețea, cu accent pe comportamentul sistemului la Point of Common Coupling (PCC), în vederea fundamentării cadrului experimental și metodologic și definirii direcției proprii de cercetare doctorală în domeniul Ingineriei sistemelor.
6.2 Obiectivele specifice	- aprofundarea cunoștințelor privind principiile, arhitecturile și metodele Hardware-in-the-Loop (HIL) utilizate pentru testarea și validarea în timp real a sistemelor de control și management energetic în microgriduri; - dezvoltarea capacității de documentare științifică utilizând baze de date internaționale și surse bibliografice relevante privind implementarea și validarea HIL a algoritmilor Multi-Agent Reinforcement Learning (MARL) în sisteme energetice complexe; - formarea competențelor de analiză critică, comparare și evaluare a arhitecturilor și metodelor de validare HIL, a interacțiunii în timp real dintre algoritmul MARL și modelul sistemului și a criteriilor utilizate pentru evaluarea performanțelor; - aprofundarea metodelor de analiză a stabilității dinamice a microgridurilor conectate la rețea, cu accent pe comportamentul la Point of Common Coupling (PCC), variațiile puterii active și reactive, tensiunii și frecvenței și influența strategiilor de control MARL asupra acestora; - identificarea criteriilor și indicatorilor de performanță, a scenariilor relevante de testare și a limitărilor soluțiilor existente pentru validarea HIL a algoritmilor MARL și evaluarea stabilității dinamice a microgridurilor; - dezvoltarea capacității de elaborare a unei sinteze bibliografice argumentate, de fundamentare a cadrului experimental și metodologic și de definire a direcției proprii de cercetare doctorală privind validarea HIL a algoritmului MARL și analiza stabilității dinamice la PCC.

7. Rezultatele învățării

7.1 Cunoștințe (<i>Rezultatul asimilării de informații prin învățare. Cunoștințele reprezintă ansamblul de fapte, principii, teorii și practici legate de un anumit domeniu de muncă sau de studiu. Pot fi teoretice și/sau faptice</i>)	La finalizarea disciplinei, studentul-doctorand/absolventul: - demonstrează cunoștințe avansate privind principiile, arhitecturile și metodele Hardware-in-the-Loop (HIL) utilizate pentru testarea și validarea în timp real a sistemelor de control și management energetic; - cunoaște metodele de implementare și validare HIL a algoritmilor Multi-Agent Reinforcement Learning (MARL) și principiile interacțiunii în timp real dintre algoritmul de control și modelul dinamic al microgridului; - cunoaște principiile și metodele de analiză a stabilității dinamice a microgridurilor conectate la rețea și parametrii relevanți pentru caracterizarea comportamentului sistemului la Point of Common Coupling (PCC); - înțelege criteriile, indicatorii de performanță și scenariile de testare utilizate pentru evaluarea performanței algoritmilor MARL și a stabilității dinamice a microgridurilor în cadrul experimentelor HIL.
7.2 Aptitudini (<i>Capacitatea de a aplica cunoștințe și de a utiliza know-how pentru a duce la îndeplinire sarcini și a rezolva probleme. Aptitudinile sunt descrise ca fiind cognitive (implicând utilizarea gândirii logice, intuitive și creative) sau practice (implicând dexteritate manuală și utilizarea de metode, materiale, unelte și instrumente)</i>)	Studentul-doctorand /absolventul este capabil: - să identifice, selecteze și analizeze critic literatura științifică relevantă privind validarea HIL a algoritmilor MARL și stabilitatea dinamică a microgridurilor; - să analizeze comparativ arhitecturile și metodele HIL și să argumenteze adecvarea acestora pentru testarea în timp real a algoritmilor de control și management energetic; - să analizeze comportamentul dinamic al microgridului la PCC prin evaluarea variațiilor puterii active și reactive, tensiunii și frecvenței, precum și a interacțiunilor dintre subsistemele microgridului și rețeaua electrică; - să evalueze influența algoritmului MARL asupra performanței și stabilității dinamice a sistemului și să selecteze criterii, indicatori și scenarii relevante pentru validarea HIL; - să identifice limitările soluțiilor existente și să fundamenteze cadrul experimental și metodologic pentru validarea HIL a algoritmului MARL și evaluarea stabilității dinamice la PCC..
7.3 Responsabilitate și autonomie (<i>Capacitatea cursantului de a aplica în mod autonom și responsabil cunoștințele și aptitudinile sale</i>)	Studentul-doctorand /absolventul: - desfășoară în mod autonom activități de documentare, analiză critică și sinteză privind metodele HIL, algoritmi MARL și stabilitatea dinamică a microgridurilor, cu respectarea principiilor eticii și integrității academice; - își asumă responsabilitatea pentru selectarea și fundamentarea arhitecturii HIL, a criteriilor de evaluare și a scenariilor de testare relevante pentru obiectivele cercetării doctorale; - argumentează în mod independent alegerea metodelor și indicatorilor utilizați pentru evaluarea performanței algoritmului MARL și analiza stabilității dinamice a microgridului la PCC;

- dezvoltă în mod autonom cadrul experimental și metodologic al cercetării și își asumă responsabilitatea pentru fundamentarea științifică a validării HIL a algoritmului MARL și a analizei stabilității dinamice la PCC.

8. Conținuturi

8.2 Studiu individual	Metode de predare	Observații
Studiarea bibliografiei fundamentale privind principiile și arhitecturile de validare Hardware-in-the-Loop (HIL) utilizate pentru testarea în timp real a sistemelor de control și management energetic în microgriduri, cu accent pe integrarea modelelor dinamice ale subsistemelor PV-BESS, convertoarelor de putere, sarcinilor și interfeței cu rețeaua electrică.	Studiu individual, analiză bibliografică	45 h
Documentarea în baze de date științifice privind metodele de implementare și validare HIL a algoritmilor de Multi-Agent Reinforcement Learning (MARL) pentru controlul și managementul energetic al microgridurilor, cu analiza arhitecturilor de testare, a interacțiunii în timp real dintre algoritmul de control și modelul sistemului și a criteriilor de evaluare a performanțelor.	Documentare în baze de date, analiză critică	25 h
Analiza critică și comparativă a literaturii privind stabilitatea dinamică a microgridurilor conectate la rețea și comportamentul acestora la Point of Common Coupling (PCC), cu accent pe variațiile puterii active și reactive, tensiunii și frecvenței, interacțiunea dintre subsistemele PV-BESS și rețeaua electrică și influența strategiilor de control MARL asupra stabilității sistemului.	Analiză comparativă, sinteză bibliografică	25 h
Elaborarea unei sinteze bibliografice privind metodele de validare HIL a algoritmilor MARL și de evaluare a stabilității dinamice a microgridurilor la PCC, cu identificarea criteriilor și indicatorilor de performanță, a scenariilor relevante de testare, a limitărilor soluțiilor existente și a direcțiilor necesare pentru fundamentarea cadrului experimental și metodologic al cercetării doctorale.	Elaborare individuală, redactare academică	30 h
Consultări periodice cu titularul disciplinei și/sau conducătorul de doctorat privind bibliografia, direcțiile de cercetare și interpretarea critică a rezultatelor din literatura de specialitate.	Tutoriat, discuții individuale	20 h
Pregătirea și susținerea colocviului pe baza studiului individual și a raportului de documentare realizat.	Studiu individual, prezentare și susținere	30 h
Bibliografie [1.] Aksan, F., Suresh, V., & Janik, P. (2024). Optimal capacity and charging scheduling of electric vehicles in a smart grid context. <i>Energies</i>, 17(11), 2718. https://www.mdpi.com/1996-1073/17/11/2718 [2.] Alshammari, N. F., Alshahr, S., & Barakat, S. (2026). How energy management strategy shapes optimal microgrid design: A comparative analysis for EV charging stations. <i>Applied Energy</i>, 407, 127352. https://www.sciencedirect.com/science/article/pii/S0306261926000048 [3.] Cho, I. S., & Kim, R. Y. (2023). Development of photovoltaic (PV) evaluation and fault detection system using hardware-in-the-loop simulation for PV applications. <i>Electronics</i>, 14(3), 674. https://www.mdpi.com/2072-666X/14/3/674 [4.] Fauziah, K., Munir, B. S., Sriyono, S., & Anwar, S. (2024). Design and experimental validation of a cluster-based virtual power plant with centralized management system in compliance with IEC standard. <i>Energies</i>, 18(19), 5300. https://www.mdpi.com/1996-1073/18/19/5300 [5.] He, W., Li, C., Cai, C., Qing, X., & Du, W. (2024). Suppressing active power fluctuations at PCC in grid-connection microgrids via multiple BESSs: A collaborative multi-agent reinforcement learning approach. <i>Applied Energy</i>, 353(Pt A), 122041. https://www.sciencedirect.com/science/article/pii/S0306261924012418 [6.] Hu, D., Ye, Z., Gao, Y., Peng, Y., & Yu, N. (2022). Multi-agent deep reinforcement learning for voltage control with coordinated active and reactive power optimization. <i>IEEE Transactions on Smart Grid</i>, 13(6), 4873-4886. https://doi.org/10.1109/TSG.2022.3185975 [7.] Kisacikoglu, M. J., Ucer, E., & Suresh, V. (2024). Development of a hardware-in-the-loop testbed for a decentralized, data-driven electric vehicle charging control algorithm. <i>IEEE Transactions on Industry Applications</i>, 60(4), 5234-5245. https://doi.org/10.1109/TIA.2024.3384480 [8.] Liang, Y., Ding, Z., Zhao, T., & Lee, W. J. (2023). Real-time operation management for battery swapping-charging system via multi-agent deep reinforcement learning. <i>IEEE Transactions on Smart Grid</i>, 14(1), 559-571. https://doi.org/10.1109/TSG.2022.3186931 [9.] Liu, X., Wang, Y., Zhang, L., & Computer, S. (2024). Multi-agent reinforcement learning for electric vehicle charging coordination with renewable energy integration. <i>IEEE Transactions on Smart Grid</i>, 15(3), 2847-2859. https://scholar.google.com/scholar?q=%22Multi-agent+reinforcement+learning+for+electric+vehicle+charging+coordination+with+renewable+energy+integration%22 [10.] Liu, Y., Wu, D., & Gao, S. (2024). Resilient control of networked microgrids using vertical federated reinforcement learning: Designs and real-time test-bed validations. <i>IEEE Transactions on Smart Grid</i>, 16(2), 1897-1910. https://doi.org/10.1109/TSG.2024.3466768 [11.] Luna, A. C., Diaz, N. L., Andrade, F., Graells, M., & Guerrero, J. M. (2020). Hardware in the loop platform for testing photovoltaic system control. <i>Applied Sciences</i>, 10(23), 8690. https://www.mdpi.com/2076-3417/10/23/8690 [12.] Maran, D., Salaorni, D., & Restelli, M. (2025). Reinforcement learning-based energy management in community microgrids: A comparative study. <i>Sustainability</i>, 17(23), 10696. https://www.mdpi.com/2071-		

1050/17/23/10696

- [13.] Myint, K. P. Y., Pahasa, J., Boonraksa, P., Boonraksa, T., & Marungsri, B. (2026). Multi-objective energy management optimization on grid-integrated microgrid using multi-agent deep reinforcement learning. *IEEE Access*, 14, 3668993. <https://doi.org/10.1109/ACCESS.2026.3668993>
- [14.] Rosero, D. G., Díaz, N. L., Trujillo, C. L., & Guerrero, J. M. (2018). Hardware-in-the-loop validation of energy management systems for microgrids: A short overview and a case study. *Energies*, 11(11), 2978. <https://www.mdpi.com/1996-1073/11/11/2978>
- [15.] Rosero, D. G., Sanabria, E., Díaz, N. L., Trujillo, C. L., Luna, A., & Andrade, F. (2023). Full-deployed energy management system tested in a microgrid cluster. *Applied Energy*, 334, 120674. <https://www.sciencedirect.com/science/article/pii/S0306261923000387>
- [16.] Santhakumar, K., Kumar, R., & Janik, P. (2025). Digital Twin for real-time and predictive optimization of EV charging in microgrids integrating renewable energy sources. *Energies*, 18(21), 5605. <https://www.mdpi.com/1996-1073/18/21/5605>
- [17.] Selvam, K., Dhiman, H. S., Pandya, D., & Sahoo, S. (2025). Hardware-in-loop implementation of an adaptive MPPT controlled PV-assisted EV charging system with vehicle-to-grid integration. *Scientific Reports*, 15(1), 11442. <https://www.nature.com/articles/s41598-025-12508-3>
- [18.] Sultanuddin, S. J., Vibin, R., & Pasha, M. J. (2024). Intelligent energy management system for microgrids using reinforcement learning. *ResearchGate Tech Reports*, 24(2), 115-128. <https://www.researchgate.net/search/publication?q=%22Intelligent%20energy%20management%20system%20for%20microgrids%20using%20reinforcement%20learning%22>
- [19.] Talihati, B., Fu, S., Zhang, B., Zhao, Y., Wang, Y., & Sun, Y. (2025). Community shared ES-PV system for managing electric vehicle loads via multi-agent reinforcement learning. *International Journal of Electrical Power and Energy Systems*, 380, 125039. <https://www.sciencedirect.com/science/article/pii/S0306261924024231>
- [20.] Tuhnitz, F., Ebell, N., Schlund, J., & Pruckner, M. (2021). Development and evaluation of a smart charging strategy for an electric vehicle fleet based on reinforcement learning. *Applied Energy*, 285, 116382. <https://www.sciencedirect.com/science/article/pii/S0306261920317566>
- [21.] Ucer, E., & Kisackoglu, M. J. (2024). Development of a hardware-in-the-loop testbed for a decentralized, data-driven electric vehicle charging control algorithm. *IEEE Transactions on Industry Applications*, 60(4), 5234-5245. <https://doi.org/10.1109/TIA.2024.3384480>
- [22.] Wang, R., & Smart, G. (2024). Reinforcement learning in microgrid energy management: Review, methods and prospects. *IET Smart Grid*, 7(4), 412-431. <https://scholar.google.com/scholar?q=%22Reinforcement+learning+in+microgrid+energy+management%3A+Review%2C+methods+and+prospects%22>
- [23.] Wang, Z., Zhang, J., & Che, L. (2024). Deep reinforcement learning based optimal energy management of multi-energy microgrids with uncertainties. *IEEE Transactions on Smart Grid*, 15(4), 3912-3925. <https://scholar.google.com/scholar?q=%22Deep+reinforcement+learning+based+optimal+energy+management+of+multi-energy+microgrids+with+uncertainties%22>
- [24.] Yang, Z., Wang, S., Deng, J., Peng, X., Jiang, N., & Li, Y. (2024). Intelligent energy management method of EV charging station with photovoltaic and energy storage system. *Proceedings of the 8th International Conference on Power Energy Systems and Applications (ICoPESA)*, 488-494. <https://doi.org/10.1109/ICoPESA61191.2024.10743376>
- [25.] Zhang, J., Che, L., & Shahidehpour, M. (2023). Distributed training and distributed execution based Stackelberg multi-agent reinforcement learning for EV charging scheduling. *IEEE Transactions on Smart Grid*, 14(6), 4976-4979. <https://doi.org/10.1109/TSG.2023.3309528>

9. Coroborarea conținuturilor disciplinei cu așteptările reprezentanților comunității epistemice, asociațiilor profesionale și angajatori reprezentativi din domeniul aferent programului

Conținuturile disciplinei sunt corelate cu direcțiile actuale de cercetare din domeniul Ingineriei sistemelor, privind testarea și validarea în timp real a sistemelor complexe de control, utilizarea tehnicilor Hardware-in-the-Loop (HIL) și evaluarea comportamentului dinamic al microgridurilor conectate la rețea. Tematica disciplinei integrează validarea algoritmilor Multi-Agent Reinforcement Learning (MARL) cu analiza stabilității dinamice și a interacțiunii microgridului cu rețeaua electrică la Point of Common Coupling (PCC). Conținuturile sunt corelate cu preocupările comunității științifice și profesionale reflectate în literatura internațională de specialitate, inclusiv în publicații IEEE, privind dezvoltarea și validarea sistemelor de control distribuit și multi-agent, testarea în timp real a strategiilor de management energetic și utilizarea platformelor HIL pentru evaluarea sistemelor energetice complexe. Bibliografia include lucrări dedicate explicit platformelor și testbed-urilor HIL, validării sistemelor de management energetic și controlului în timp real al microgridurilor. Conținuturile disciplinei răspund, de asemenea, cerințelor mediului economic și ale angajatorilor din domeniile sistemelor energetice inteligente, automatizărilor, microgridurilor, surselor regenerabile, stocării energiei și controlului avansat, prin dezvoltarea capacității de analiză și evaluare a performanței și stabilității sistemelor, precum și de fundamentare a metodelor și scenariilor necesare validării experimentale a algoritmilor de control. Disciplina contribuie la dezvoltarea competențelor necesare abordării sistemice a interacțiunii dintre algoritmul de control, microgrid și rețeaua electrică și la fundamentarea unei cercetări doctorale privind validarea HIL a algoritmului MARL și analiza stabilității dinamice la PCC, creând premise pentru evaluarea performanței, stabilității și robusteții soluțiilor dezvoltate în cadrul cercetării doctorale. Componenta privind PCC este susținută explicit de literatura referitoare la controlul fluctuațiilor de putere la punctul de cuplare prin abordări MARL colaborative.

10. Evaluare

Tip activitate	10.1 Criterii de evaluare	10.2 Metode de evaluare	10.3 Pondere din nota finală
10.4 Colocviu	Corectitudinea și completitudinea cunoștințelor dobândite privind principiile și arhitecturile Hardware-in-the-Loop (HIL), validarea în timp real a algoritmilor Multi-Agent Reinforcement Learning (MARL) și analiza stabilității dinamice a microgridurilor conectate la rețea; capacitatea de identificare, selectare, analiză critică și sinteză a literaturii științifice de specialitate; capacitatea de analiză comparativă a arhitecturilor și metodelor de validare HIL și de evaluare a interacțiunii în timp real dintre algoritmul MARL și modelul sistemului; capacitatea de analiză a comportamentului dinamic la Point of Common Coupling (PCC), prin raportare la puterea activă și reactivă, tensiune și frecvență; selectarea și argumentarea criteriilor, indicatorilor de performanță și scenariilor de testare; identificarea limitărilor soluțiilor existente și fundamentarea științifică a cadrului experimental și metodologic pentru validarea HIL a algoritmului MARL și analiza stabilității dinamice la PCC.	Colocviu oral și evaluarea raportului individual de studiu	100%
10.5 Proiect	-	-	-
10.6 Standard minim de performanță			
Pentru promovarea disciplinei, studentul trebuie să îndeplinească cumulativ următoarele condiții:			
Să obțină minimum 50% din punctajul aferent colocviului și să demonstreze atingerea rezultatelor învățării prin: - identificarea, selectarea și utilizarea adecvată a literaturii științifice relevante privind validarea Hardware-in-the-Loop (HIL) a algoritmilor Multi-Agent Reinforcement Learning (MARL) și analiza stabilității dinamice a microgridurilor; - cunoașterea principiilor, arhitecturilor și metodelor HIL utilizate pentru testarea și validarea în timp real a algoritmilor de control și management energetic; - realizarea unei analize critice și a unei sinteze bibliografice privind metodele de validare HIL și evaluarea comportamentului dinamic al microgridurilor conectate la rețea, fundamentată pe surse științifice actuale și relevante; - analiza și argumentarea criteriilor, indicatorilor de performanță și scenariilor de testare relevante pentru evaluarea algoritmului MARL și a stabilității dinamice la Point of Common Coupling (PCC); - identificarea limitărilor soluțiilor existente și fundamentarea cadrului experimental și metodologic pentru validarea HIL a algoritmului MARL și analiza stabilității dinamice la PCC; - utilizarea corectă a terminologiei științifice și respectarea principiilor eticii și integrității academice în elaborarea și prezentarea raportului individual de studiu.			
Standardul minim de performanță validează atingerea rezultatelor învățării definite la pct. 7.			

Fișa disciplinei corespunde planului de învățământ care se aplică pentru anul I începând cu anul universitar 2027-2028.

Data completării

Titularul de curs (Conducator doctorat)
Prof. univ. dr. ing. Florin DRAGOMIR

Titularul de laborator

Data avizării în
CSD

Director SDSI
Prof. univ. dr. ing. Dinu COLȚUC

Data avizării în
CSUD

Director CSUD
Prof. univ. dr. ing. Rodica Mariana ION