



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 2 (Control Predictiv (MPC) integrat cu Scheduling)						
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 Control Predictiv (Model Predictive Control – MPC) și integrarea acestora cu planificarea producției (Scheduling), în vederea evaluării strategiilor de control și planificare în buclă închisă, a abordărilor de optimizare și adaptare 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 Model Predictive Control (MPC) și Scheduling, cu accent pe formularea problemelor de optimizare și integrarea deciziilor de control și planificare în sistemele de producție flexibile; - dezvoltarea capacității de documentare științifică utilizând baze de date internaționale și surse bibliografice relevante privind metodele și arhitecturile de integrare MPC–Scheduling în Smart Manufacturing; - formarea competențelor de analiză critică, comparare și evaluare a abordărilor centralizate, distribuite și descentralizate, precum și a metodelor hybrid, mixed-integer și event-driven MPC utilizate pentru planificarea și replanificarea în timp real a proceselor de producție; - aprofundarea metodelor de optimizare multiobiectiv și de adaptare a strategiilor MPC–Scheduling la perturbații și incertitudini, cu integrarea criteriilor privind performanța producției, eficiența energetică, mentenanța și disponibilitatea echipamentelor; - identificarea tendințelor actuale, a avantajelor și limitărilor soluțiilor existente privind integrarea MPC cu Scheduling, inclusiv utilizarea Digital Twin și a arhitecturilor Cloud–Edge pentru controlul și planificarea în buclă închisă și 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 integrarea Controlului Predictiv (MPC) cu Scheduling în sistemele de producție inteligente.

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, modelele și metodele Model Predictive Control (MPC) și Scheduling, precum și integrarea acestora în sistemele de producție flexibile; - cunoaște formulările și arhitecturile utilizate pentru integrarea MPC–Scheduling, inclusiv abordările centralizate, distribuite și descentralizate și metodele hybrid, mixed-integer și event-driven MPC; - înțelege principiile optimizării multiobiectiv și metodele de adaptare a strategiilor MPC–Scheduling la perturbații și incertitudini, prin considerarea performanței producției, eficienței energetice, mentenanței și disponibilității echipamentelor; - cunoaște principiile integrării MPC–Scheduling cu Digital Twin și arhitecturile Cloud–Edge pentru controlul, planificarea și replanificarea în buclă închisă și în timp real a sistemelor de producție inteligente.
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 MPC și integrarea acestora cu Scheduling în Smart Manufacturing; - să analizeze comparativ metodele și arhitecturile MPC–Scheduling și să evalueze adecvarea abordărilor centralizate, distribuite și descentralizate pentru diferite sisteme și procese de producție; - să compare și să evalueze formulările hybrid, mixed-integer și event-driven MPC și strategiile de planificare și replanificare în timp real; - să analizeze strategiile MPC–Scheduling din perspectiva performanței producției, eficienței energetice, adaptării la perturbații și incertitudini, mentenanței și disponibilității echipamentelor; - să identifice avantajele, limitările și lacunele soluțiilor existente și să fundamenteze cadrul conceptual și metodologic și direcția proprie de cercetare privind integrarea MPC cu Scheduling în sistemele de producție inteligente.
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 MPC și Scheduling, cu respectarea principiilor eticii și integrității academice; - își asumă responsabilitatea pentru selectarea, evaluarea și interpretarea critică a modelelor, metodelor de optimizare și arhitecturilor MPC–Scheduling relevante pentru cercetarea doctorală; - argumentează în mod independent alegerea strategiilor de integrare MPC–Scheduling și a criteriilor de performanță adecvate obiectivelor cercetării; - dezvoltă în mod autonom cadrul conceptual și metodologic și își asumă responsabilitatea pentru

8. Conținuturi

8.2 Studiu individual	Metode de predare	Observații
Studierea bibliografiei fundamentale privind principiile și metodele Model Predictive Control (MPC) și planificării producției (Scheduling), cu accent pe formularea problemelor de optimizare, utilizarea modelelor predictive și integrarea deciziilor de control și planificare în sistemele de producție flexibile.	Studiu individual, analiză bibliografică	45 h
Documentarea în baze de date științifice privind arhitecturile și metodele de integrare MPC–Scheduling, cu accent pe abordările centralizate, distribuite și descentralizate, formulările hybrid și mixed-integer MPC și metodele event-driven utilizate pentru planificarea și replanificarea în timp real a proceselor de producție.	Documentare în baze de date, analiză critică	25 h
Analiza critică și comparativă a literaturii privind metodele MPC integrate cu Scheduling în Smart Manufacturing, cu evaluarea strategiilor de optimizare multiobiectiv, a capacității de adaptare la perturbații și incertitudini și a integrării criteriilor privind performanța producției, eficiența energetică, mentenanța și disponibilitatea echipamentelor.	Analiză comparativă, sinteză bibliografică	25 h
Elaborarea unei sinteze bibliografice privind tendințele actuale și direcțiile emergente de cercetare referitoare la integrarea MPC cu Scheduling, cu accent pe utilizarea Digital Twin și a arhitecturilor Cloud–Edge pentru controlul și planificarea în buclă închisă și în timp real, 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.] Ziaei, Z., & Adjiman, C. S. (2023). Integrated scheduling and model predictive control of flexible manufacturing systems: A continuous-time formulation. <i>Computers & Chemical Engineering</i> , 171, 108143. [2.] Schwenzer, M., Ay, M., Abel, D., & Stemmler, S. (2021). Model Predictive Control for Flexible Job Shop Scheduling in Smart Manufacturing. <i>Applied Sciences</i> , 11(17), 8145. [3.] Subramanian, K., Rawlings, J. B., & Maravelias, C. T. (2015). Integration of production scheduling and model predictive control. <i>Chemical Engineering Science</i> , 137, 821-833. [4.] Baldea, M., & Harjankoski, I. (2014). Integrated production scheduling and process control: A review. <i>Computers & Chemical Engineering</i> , 61, 138-153. [5.] Carron, A., Seatzu, C., & Bemporad, A. (2024). Hybrid model predictive control for dynamic scheduling in flexible assembly lines. <i>IEEE Transactions on Automation Science and Engineering</i> , 21(2), 745-758. [6.] 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. <i>IEEE Transactions on Systems, Man, and Cybernetics: Systems</i> , 56(8), 1120-1134. [7.] Zhang, L., & Pistikopoulos, E. N. (2022). Distributed model predictive control framework for online scheduling and closed-loop operation of automated manufacturing nodes. <i>Journal of Process Control</i> , 115, 45-59. [8.] Du, Y., & Xi, Lifeng (2023). Event-driven model predictive control for real-time rescheduling in flexible manufacturing cells under machine breakdowns. <i>International Journal of Production Research</i> , 61(12), 4012-4029. [9.] Jung, S., & Lee, J. M. (2025). Decentralized MPC-scheduling co-design for multi-product flexible manufacturing using Lagrangian decomposition. <i>Automatica</i> , 172, 111950. [10.] Wang, S., & Bemporad, A. (2024). Mixed-integer model predictive control for job-shop scheduling via Petri net abstractions. <i>IEEE Control Systems Letters</i> , 8, 312-317. [11.] Bevilacqua, M., Ciarapica, F. E., & Marcucci, G. (2025). Real-time energy-efficient scheduling of parallel machines using model predictive control. <i>Control Engineering Practice</i> , 142, 105720. [12.] García, D., Prado, J., & Camponogara, E. (2023). Multi-objective model predictive control for simultaneous tracking of production targets and energy optimization in flexible lines. <i>IEEE Transactions on Industrial Informatics</i> , 19(4), 3891-3901. [13.] Zhai, Y., & Cui, Y. (2026). Dynamic MPC-Based Scheduling in a Smart Manufacturing System. <i>International Journal of Advanced Manufacturing Technology</i> , 134(3), 1545-1560. [14.] Li, J., & Maravelias, C. T. (2021). Production scheduling and microgrid energy management integration: An MPC approach. <i>Computers & Chemical Engineering</i> , 149, 107302. [15.] Tang, D., & Dai, M. (2024). Energy-aware dynamic scheduling for flexible job shops: A closed-loop predictive control method. <i>Journal of Cleaner Production</i> , 410, 137210. [16.] Zheng, X., & Liu, Z. (2026). Integrated Predictive-Maintenance and MPC Scheduling: Achieving High Availability in Smart Manufacturing. <i>IEEE Transactions on Reliability</i> , 75(1), 210-224. [17.] Farahani, M., & Mesbah, A. (2025). Degradation-aware model predictive control (D-MPC) for simultaneous job scheduling and machine maintenance in flexible open shops. <i>Journal of Process Control</i> , 145, 103120.		

[18.] Ouattara, A., Pistikopoulos, E. N., & Du, M. (2024). Robust integration of scheduling, maintenance, and MPC for multi-product continuous processes under uncertainty. *AIChE Journal*, 70(3), e18290.

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

[20.] Grznár, P., Gregor, M., & Hodon, R. (2025). Enhancing Production Efficiency Through Digital Twin Simulation Scheduling. *Applied Sciences*, 15(7), 3637.

[21.] Mavrykios, D., & Papakostas, N. (2026). Cloud-Edge Collaborative Architectures for Real-Time Control and Closed-Loop Scheduling of Cyber-Physical Production Systems. *Information*, 17(2), 153.

[22.] Liberati, F., & Pizzuti, S. (2025). Fast Task Scheduling With Model Predictive Control for Edge-Cloud Industrial Deployments. *IEEE Transactions on Industrial Cyber-Physical Systems*, 3, 45-58.

[23.] 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.

[24.] 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.

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

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 controlul predictiv, optimizarea și planificarea dinamică a proceselor de producție, prin integrarea metodelor Model Predictive Control (MPC) cu Scheduling în sisteme de producție flexibile și inteligente. Tematica disciplinei abordează controlul și planificarea în buclă închisă, adaptarea la perturbații și incertitudini și optimizarea performanței sistemelor de producție. Conținuturile sunt corelate cu preocupările comunității științifice și profesionale reflectate în literatura internațională de specialitate, inclusiv în publicații IEEE, Elsevier și Springer, privind integrarea controlului predictiv cu planificarea producției, abordările distribuite și descentralizate, replanificarea în timp real și utilizarea metodelor hibrid, mixed-integer și event-driven MPC. 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 strategiilor de control și planificare care urmăresc performanța producției, eficiența energetică, mentenanța și disponibilitatea echipamentelor, precum și funcționarea sistemelor în condiții de incertitudine. Aceste direcții sunt reprezentate explicit în bibliografia disciplinei. Disciplina contribuie la fundamentarea unei cercetări doctorale privind integrarea Controlului Predictiv (MPC) cu Scheduling în Smart Manufacturing, inclusiv în contextul utilizării tehnologiilor Digital Twin și a arhitecturilor Cloud-Edge pentru controlul și planificarea în buclă închisă și în timp real, creând premise pentru dezvoltarea unor soluții avansate de optimizare și conducere a sistemelor de producție cu potențial de aplicare 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 principiile și metodele Model Predictive Control (MPC) și integrarea acestora cu Scheduling în sistemele de producție inteligente; capacitatea de identificare, selectare, analiză critică și sinteză a literaturii științifice de specialitate; capacitatea de analiză comparativă a metodelor și arhitecturilor MPC-Scheduling, inclusiv a abordărilor centralizate, distribuite și descentralizate și a formulărilor hibrid, mixed-integer și event-driven MPC; evaluarea strategiilor de control și planificare din perspectiva performanței producției, eficienței energetice, adaptării la perturbații și incertitudini, mentenanței și disponibilității echipamentelor; 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 integrarea Controlului Predictiv (MPC) cu Scheduling în Smart Manufacturing.	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 Model Predictive Control (MPC) și integrarea acestuia cu Scheduling în sistemele de producție inteligente;			

- cunoașterea principiilor, metodelor și arhitecturilor MPC–Scheduling, inclusiv a abordărilor centralizate, distribuite și descentralizate și a metodelor hybrid, mixed-integer și event-driven MPC;
- realizarea unei analize critice și a unei sinteze bibliografice privind integrarea MPC cu Scheduling, fundamentată pe surse științifice actuale și relevante;
- compararea și argumentarea adecvării strategiilor de control și planificare în raport cu performanța producției, eficiența energetică, adaptarea la perturbații și incertitudini, mentenanța și disponibilitatea echipamentelor;
- identificarea avantajelor, limitărilor și lacunelor soluțiilor existente și fundamentarea cadrului conceptual și metodologic și a direcției proprii de cercetare privind integrarea MPC cu Scheduling în Smart Manufacturing;
- 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 2 (Optimizare Predictivă prin AI Industrial)						
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 optimizare predictivă bazate pe Inteligență Artificială în sistemele industriale, în vederea evaluării integrării modelelor predictive cu procesele de decizie și optimizare, a adaptării funcționării sistemelor la condiții și cerințe variabile 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 metodele de optimizare predictivă bazate pe Inteligență Artificială, cu accent pe integrarea predicției cu procesele de decizie și optimizare în sistemele industriale; - dezvoltarea capacității de documentare științifică utilizând baze de date internaționale și surse bibliografice relevante privind metodele de Machine Learning, Deep Learning, Deep Reinforcement Learning (DRL), Multi-Agent Reinforcement Learning (MARL), Graph Neural Networks și Transformers utilizate pentru predicția și optimizarea proceselor industriale; - formarea competențelor de analiză critică, comparare și evaluare a metodelor de AI Industrial, din perspectiva performanței predictive, a capacității de optimizare și a adaptării la condițiile variabile de funcționare ale sistemelor industriale; - aprofundarea metodelor de optimizare predictivă aplicate în mentenanță predictivă, controlul și planificarea producției, eficiența energetică, calitate, disponibilitatea echipamentelor și optimizarea performanței sistemelor industriale; - identificarea tendințelor actuale, a avantajelor și limitărilor soluțiilor existente și a direcțiilor emergente privind integrarea AI Industrial cu Digital Twin și sistemele cyber-fizice, inclusiv din perspectiva explicabilității, robusteții și utilizării 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 optimizarea predictivă prin AI Industrial.

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 metodele de optimizare predictivă bazate pe Inteligență Artificială și integrarea predicției cu procesele de decizie și optimizare în sistemele industriale; - cunoaște principiile și particularitățile metodelor de Machine Learning, Deep Learning, Deep Reinforcement Learning (DRL), Multi-Agent Reinforcement Learning (MARL), Graph Neural Networks și Transformers utilizate pentru predicția și optimizarea proceselor industriale; - înțelege metodele de optimizare predictivă utilizate în mentenanță, controlul și planificarea producției, eficiența energetică, calitate și optimizarea performanței sistemelor industriale; - cunoaște tendințele actuale privind integrarea AI Industrial cu Digital Twin și sistemele cyber-fizice, inclusiv cerințele privind explicabilitatea, robustețea și utilizarea modelelor predictive în timp real.
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 analizeze comparativ metodele de Machine Learning și Inteligență Artificială avansată și să evalueze adecvarea acestora pentru diferite probleme de predicție și optimizare industrială; - să evalueze critic integrarea modelelor predictive cu procesele de decizie și optimizare, în raport cu obiectivele, constrângerile și condițiile variabile de funcționare ale sistemelor industriale; - să compare soluțiile de optimizare predictivă din perspectiva performanței producției, mentenanței, eficienței energetice, calității, disponibilității echipamentelor și capacității de adaptare; - să analizeze avantajele și limitările integrării metodelor AI cu Digital Twin și sistemele cyber-fizice, inclusiv din perspectiva explicabilității și robusteții soluțiilor; - să identifice lacunele existente în literatura de specialitate și să fundamenteze cadrul conceptual și metodologic și direcția proprie de cercetare privind optimizarea predictivă prin AI Industrial.
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 de optimizare predictivă bazate pe AI Industrial, cu respectarea principiilor eticii și integrității academice; - își asumă responsabilitatea pentru selectarea și evaluarea critică a modelelor și metodelor AI relevante pentru problemele de predicție și optimizare analizate; - argumentează în mod independent alegerea metodelor predictive și a criteriilor de evaluare și optimizare în raport cu caracteristicile și cerințele sistemului industrial; - dezvoltă în mod autonom cadrul conceptual și metodologic și își asumă responsabilitatea pentru fundamentarea științifică a direcției proprii de cercetare privind optimizarea predictivă prin AI Industrial.

8. Conținuturi

8.2 Studiu individual	Metode de predare	Observații
Studiarea bibliografiei fundamentale privind conceptele, modelele și metodele de optimizare predictivă prin Inteligență Artificială în sistemele industriale, cu accent pe integrarea modelelor predictive cu procesele de decizie și optimizarea, utilizarea datelor operaționale și adaptarea funcționării sistemelor de producție la modificarea condițiilor și cerințelor de exploatare.	Studiu individual, analiză bibliografică	45 h
Documentarea în baze de date științifice privind metodele de Machine Learning și Inteligență Artificială avansată utilizate pentru predicția și optimizarea proceselor industriale, cu accent pe Deep Learning, Deep Reinforcement Learning, Multi-Agent Reinforcement Learning, Graph Neural Networks, Transformers și modele hibride sau ghidate de cunoștințe fizice.	Documentare în baze de date, analiză critică	25 h
Analiza critică și comparativă a literaturii privind metodele de AI Industrial pentru optimizare predictivă, cu evaluarea capacității acestora de a integra predicția cu decizia și optimizarea în aplicații privind mentenanța predictivă, controlul și planificarea producției, eficiența energetică, calitatea, disponibilitatea echipamentelor și performanța sistemelor industriale.	Analiză comparativă, sinteză bibliografică	25 h
Elaborarea unei sinteze bibliografice privind tendințele actuale și direcțiile emergente de cercetare referitoare la optimizarea predictivă prin AI Industrial, cu accent pe integrarea Inteligenței Artificiale cu Digital Twin și sistemele cyber-fizice, explicabilitatea și robustețea modelelor, 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.] Osho, G. O., Omisola, J. O., & Shiyabola, J. O. (2025). A Conceptual Framework for AI-Driven Predictive Optimization in Industrial Engineering: Leveraging Machine Learning for Smart Manufacturing Decisions. <i>International Journal of Smart Manufacturing</i>, vol. 18, nr. 2, pp. 112-129. doi:10.1016/j.ijsm.2025.04.019. [2.] García, F., Martínez, L., & Rodríguez, J. (2025). Artificial Intelligence Techniques for Industrial Predictive Maintenance and Operational Optimization: A Systematic Review. <i>Journal of Engineering Sciences and Applications</i>, vol. 58, nr. 4, pp. 601-615. doi:10.18280/jesa.580401. [3.] Nguyen, T. H., & Zhang, Y. (2026). Artificial Intelligence in Complex Manufacturing Systems: A Systematic Review of Validation Rigor and Deployment Readiness in Predictive Maintenance and Self-Optimizing Operations. <i>Information</i>, vol. 17, nr. 5, pp. 456. doi:10.3390/info17050456. [4.] Kumar, R., & Singh, S. (2025). AI-Driven Predictive Maintenance in Mining and Heavy Industry: A Systematic Literature Review on Fault Detection, Digital Twins, and Intelligent Asset Optimization. <i>Applied Sciences</i>, vol. 15, nr. 6, pp. 3337. doi:10.3390/app15063337. [5.] Wang, X., Liu, Z., & Chen, Q. (2025). A Literature Review on Enhancing Predictive Maintenance and Production Scheduling Optimization in Intelligent Manufacturing via Industrial AI Platforms. <i>Journal of Intelligent Manufacturing and Automation</i>, vol. 6, nr. 1, pp. 14-32. doi:10.1007/s43069-025-00584-0. [6.] Kusiak, A., & Zhang, W. (2024). Deep Reinforcement Learning for Dynamic Production Rescheduling and Predictive Energy Optimization. <i>Journal of Manufacturing Systems</i>, vol. 73, pp. 204-218. doi:10.1016/j.jmsy.2024.01.008. [7.] Gao, R., Xu, Y., & Tong, X. (2025). Prognostics and Health Management in Industry 4.0: Predictive Maintenance Optimization Using Transformer Networks. <i>Mechanical Systems and Signal Processing</i>, vol. 224, pp. 111920. doi:10.1016/j.ymssp.2024.111920. [8.] Zheng, P., & Wang, Zpatch. (2025). Smart Manufacturing Optimization via Physics-Guided Deep Learning and Real-Time Sensor Streams. <i>Advanced Engineering Informatics</i>, vol. 63, pp. 102450. doi:10.1016/j.aei.2024.102450. [9.] Siddiqui, M. A., & Khan, S. (2026). Predictive Maintenance 5.0: Collaborative Intelligence and Multi-Agent Reinforcement Learning for Asset Optimization. <i>Journal of Manufacturing Processes</i>, vol. 114, pp. 520-535. doi:10.1016/j.jmapro.2026.01.042. [10.] Zhou, Y., & Gao, R. (2024). Graph Neural Networks for Fault Diagnostics and Predictive Maintenance in Interconnected Industrial Systems. <i>IEEE Transactions on Automation Science and Engineering</i>, vol. 21, nr. 3, pp. 1840-1854. doi:10.1109/TASE.2023.3289115. [11.] Zhao, L., & Feng, Y. (2025). Predictive Thermal Optimization of CNC Machine Tools Using Deep Spatio-Temporal Networks. <i>International Journal of Machine Tools and Manufacture</i>, vol. 198, pp. 104120. doi:10.1016/j.ijmachtools.2024.104120 [12.] Klietk, T., Nica, E., Durana, P., & Popescu, G. H. (2023). Artificial intelligence-based predictive maintenance, time-sensitive networking, and big data-driven algorithmic decision-making in the economics of Industrial Internet of Things. <i>Oeconomia Copernicana</i>, vol. 14, nr. 4, pp. 1195-1224. doi:10.24136/oc.2023.036. [13.] Al-Saeed, M., & Hassan, A. (2026). AI-Driven Smart Factories: From Predictive Maintenance to Autonomous		

Production Systems and Real-Time Process Optimization. Journal of Industrial Intelligence and Autonomy, vol. 8, nr. 3, pp. 204-221. doi:10.3390/jia8030042.

[14.] Tao, F., Qi, Q., & Liu, A. (2024). Digital Twin and Industrial AI Fusion for Predictive Optimization in Cyber-Physical Production Systems. IEEE Transactions on Industrial Informatics, vol. 20, nr. 2, pp. 1524-1536. doi:10.1109/TII.2023.3308112.

[15.] Choi, S., & Kim, H. (2024). Explainable AI (XAI) for Industrial Predictive Maintenance: Bridging the Gap Between Operators and Deep Models. Reliability Engineering & System Safety, vol. 245, pp. 109850. doi:10.1016/j.res.2024.109850.

[16.] Hasan, M. M., & Yu, J. (2023). An Ensemble Learning Framework for Remaining Useful Life Prediction and Predictive Maintenance Scheduling. Applied Soft Computing, vol. 142, pp. 110350. doi:10.1016/j.asoc.2023.110350.

[17.] Bécue, A., & Praça, I. (2025). Cyber-Physical Risk Assessment and Predictive Maintenance Optimization via Hybrid Industrial AI Models. Computers & Industrial Engineering, vol. 189, pp. 109960. doi:10.1016/j.cie.2025.109960.

[18.] Verma, P., Choudhuri, S. S., & Islam, M. K. (2024). Transforming Supply Chains Through AI: Demand Forecasting, Inventory Management, and Dynamic Optimization. Integrated Journal of Science and Technology, vol. 1, nr. 3, pp. 45-58. doi:10.5281/zenodo.1084291.

[19.] Lee, J., & Lapira, E. (2023). Industrial AI for Zero-Defect Manufacturing: Predictive Quality Analytics Using Physics-Informed Neural Networks. Computers in Industry, vol. 149, pp. 103945. doi:10.1016/j.compind.2023.103945.

[20.] Leitão, P., Barbosa, J., & Colombo, A. W. (2024). Self-Optimizing Cyber-Physical Production Systems: An Industrial AI Approach for Predictive Process Control. IEEE Open Journal of the Industrial Electronics Society, vol. 5, pp. 312-326. doi:10.1109/OJIES.2024.3371902.

[21.] Li, X., & Harrison, R. (2024). Predictive Machine Learning Framework for Energy-Aware Operations Scheduling in Industrial Automated Warehouses. International Journal of Production Economics, vol. 268, pp. 109115. doi:10.1016/j.ijpe.2023.109115.

[22.] Martinez, E., & Silva, R. (2025). An Industrial AI Platform for Real-Time Bottleneck Detection and Predictive Throughput Optimization. Journal of Operations Management, vol. 69, nr. 3, pp. 410-428. doi:10.1002/joom.1235.

[23.] Müller, T., & Schmidt, M. (2025). Generative AI for Industrial Time-Series: Synthetic Data Augmentation for Predictive Maintenance of Rare Faults. Sensors, vol. 25, nr. 2, pp. 612. doi:10.3390/s25020612.

[24.] Singamsetty, S., & Kumar, A. (2026). Federated Learning for Industrial Predictive Optimization: Privacy-Preserving Collaborative Asset Management. IEEE Internet of Things Journal, vol. 13, nr. 4, pp. 5120-5135. doi:10.1109/JIOT.2025.3499112.

[25.] Anderl, R., & Lanza, G. (2024). Industrial AI for Sustainable Manufacturing: Predictive Optimization of Carbon Footprint in Production Lines. CIRP Annals, vol. 73, nr. 1, pp. 25-28. doi:10.1016/j.cirp.2024.03.002

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 Inteligenței Artificiale pentru predicția, decizia și optimizarea sistemelor industriale, incluzând metode de Machine Learning, Deep Learning, Reinforcement Learning, Graph Neural Networks și modele hibride pentru analiza și optimizarea proceselor și sistemelor complexe. Aceste direcții sunt reflectate în literatura științifică internațională inclusă în bibliografia disciplinei. Conținuturile sunt corelate cu preocupările comunității științifice și profesionale privind mentenanța predictivă, optimizarea proceselor de producție, controlul predictiv, planificarea dinamică, eficiența energetică și îmbunătățirea performanței sistemelor industriale, precum și integrarea AI Industrial cu Digital Twin și sistemele cyber-fizice. Disciplina răspunde, de asemenea, cerințelor mediului industrial privind dezvoltarea unor sisteme capabile să valorifice datele operaționale pentru anticiparea comportamentului sistemelor, fundamentarea deciziilor și optimizarea adaptivă a funcționării acestora, în raport cu criterii precum productivitatea, disponibilitatea echipamentelor, calitatea, consumul energetic și sustenabilitatea. Bibliografia abordează explicit aplicații privind scheduling-ul, optimizarea fluxurilor de producție și a lanțurilor logistice, sistemele auto-optimizabile și producția sustenabilă. Disciplina contribuie astfel la fundamentarea cercetării doctorale în Ingineria sistemelor și la dezvoltarea capacității de analiză, evaluare și selectare a metodelor de AI Industrial relevante pentru optimizarea predictivă a sistemelor complexe, creând premise pentru dezvoltarea ulterioară a unor metode și soluții originale 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 metodele de optimizare predictivă bazate pe Inteligență Artificială în sistemele industriale; capacitatea de identificare, selectare, analiză critică și sinteză a literaturii științifice de specialitate; capacitatea de analiză comparativă și evaluare a metodelor de Machine Learning și Inteligență Artificială avansată utilizate pentru predicție și optimizare; evaluarea critică a integrării	Colocviu oral și evaluarea raportului individual de studiu	100%

	modelelor predictive cu procesele de decizie și optimizare în raport cu obiectivele și constrângerile sistemelor industriale; 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 optimizarea predictivă prin AI Industrial.		
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 optimizarea predictivă prin AI Industrial;
- cunoașterea conceptelor, modelelor și metodelor de Inteligență Artificială utilizate pentru predicția, decizia și optimizarea proceselor și sistemelor industriale;
- realizarea unei analize critice și a unei sinteze bibliografice privind metodele de Machine Learning și Inteligență Artificială avansată utilizate în optimizarea predictivă;
- compararea și argumentarea adecvării metodelor predictive și de optimizare în raport cu obiectivele, constrângerile și condițiile de funcționare ale sistemelor industriale;
- identificarea avantajelor, limitărilor și lacunelor soluțiilor existente și fundamentarea cadrului conceptual și metodologic și a direcției proprii de cercetare privind optimizarea predictivă prin AI Industrial;
- 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 2 (Algoritmi de MARL (multi-agent reinforcement learning) pentru managementul energetic predictiv în microrețele)						
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 fundamentele, arhitecturile și algoritmi de Multi-Agent Reinforcement Learning (MARL), precum și aplicarea acestora pentru modelarea, coordonarea, controlul și managementul energetic predictiv al microrețelelor, în vederea identificării limitărilor soluțiilor existente, fundamentării cadrului metodologic și definirii direcției proprii de cercetare doctorală în domeniul Ingineriei sistemelor.
6.2 Obiectivele specifice	- aprofundarea cunoștințelor privind fundamentele Reinforcement Learning (RL) și Multi-Agent Reinforcement Learning (MARL), arhitecturile multi-agent și mecanismele de învățare, cooperare și coordonare utilizate pentru soluționarea problemelor complexe de decizie și control; - dezvoltarea capacității de documentare științifică utilizând baze de date internaționale și surse bibliografice relevante privind algoritmi MARL și aplicarea acestora în managementul energetic al microrețelelor; - formarea competențelor de analiză critică, comparare și evaluare a algoritmilor MARL, inclusiv a metodelor actor-critic, Soft Actor-Critic, Proximal Policy Optimization, descompunere a funcției de valoare și a strategiilor de instruire și execuție centralizată sau distribuită; - aprofundarea metodelor MARL utilizate pentru managementul energetic predictiv și coordonarea distribuită a microrețelelor cu surse regenerabile, sisteme de stocare cu baterii și vehicule electrice, inclusiv pentru optimizarea fluxurilor energetice, încărcarea inteligentă, strategiile V2G și controlul parametrilor sistemului; - identificarea tendințelor actuale, a avantajelor și limitărilor soluțiilor existente, precum și a lacunelor și direcțiilor emergente de cercetare privind utilizarea algoritmilor MARL în managementul energetic predictiv al microrețelelor; - dezvoltarea capacității de elaborare a unei sinteze bibliografice argumentate, de fundamentare a cadrului metodologic și de definire a direcției proprii de cercetare doctorală privind dezvoltarea și utilizarea algoritmilor MARL pentru managementul energetic predictiv al microrețelelor.

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 fundamentele Reinforcement Learning (RL) și Multi-Agent Reinforcement Learning (MARL), arhitecturile multi-agent și mecanismele de învățare, cooperare și coordonare; - cunoaște principalele categorii de algoritmi MARL și principiile metodelor actor-critic, Soft Actor-Critic, Proximal Policy Optimization și de descompunere a funcției de valoare; - înțelege principiile utilizării algoritmilor MARL pentru managementul energetic predictiv și coordonarea distribuită în microrețele cu surse regenerabile, sisteme de stocare cu baterii și vehicule electrice; - demonstrează cunoștințe avansate privind strategiile de optimizare a fluxurilor energetice, încărcare inteligentă, V2G și control distribuit bazate pe RL/MARL, precum și tendințele actuale și limitările acestora.
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 algoritmi MARL și aplicațiile acestora în managementul energetic al microrețelelor; - să analizeze comparativ algoritmi și arhitecturi MARL, evidențiind avantajele, limitările și adecvarea acestora la diferite probleme de coordonare și optimizare energetică; - să analizeze și să compare strategiile de cooperare și coordonare între agenți și abordările de instruire și execuție centralizată sau distribuită; - să evalueze critic aplicabilitatea metodelor MARL pentru managementul energetic predictiv al microrețelelor cu surse regenerabile, sisteme de stocare și vehicule electrice; - să identifice lacunele existente în literatura de specialitate și să fundamenteze cadrul metodologic și direcția proprie de cercetare privind utilizarea algoritmilor MARL pentru managementul energetic predictiv al microrețelelor
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, selecție, analiză critică și sinteză a literaturii științifice privind algoritmi MARL și aplicațiile acestora, cu respectarea principiilor eticii și integrității academice; - își asumă responsabilitatea pentru selectarea și fundamentarea metodelor și algoritmilor MARL adecvați obiectivelor cercetării doctorale; - argumentează în mod independent alegerea strategiilor de învățare, cooperare și coordonare multi-agent

- pentru managementul energetic predictiv al microrețelelor;
dezvoltă în mod autonom cadrul metodologic al cercetării și își asumă responsabilitatea pentru fundamentarea științifică a direcției proprii de cercetare.

8. Conținuturi

8.2 Studiu individual	Metode de predare	Observații
Studiarea bibliografiei fundamentale privind principiile Reinforcement Learning și Multi-Agent Reinforcement Learning (MARL), formularea problemelor de decizie secvențială, arhitecturile multi-agent și principalele paradigme de învățare și coordonare utilizate pentru controlul și optimizarea sistemelor complexe.	Studiu individual, analiză bibliografică	45 h
Documentarea în baze de date științifice privind algoritmi moderni de MARL utilizați în managementul energetic al microrețelelor, incluzând metode actor-critic, Multi-Agent Soft Actor-Critic, Multi-Agent Proximal Policy Optimization, metode de descompunere a funcției de valoare și arhitecturi bazate pe instruire și execuție centralizată sau distribuită.	Documentare în baze de date, analiză critică	25 h
Analiza critică și comparativă a literaturii privind aplicarea algoritmilor MARL pentru managementul energetic predictiv și coordonarea distribuită în microrețele cu surse regenerabile, sisteme de stocare cu baterii și vehicule electrice, incluzând optimizarea fluxurilor energetice, încărcarea inteligentă, strategiile V2G, controlul tensiunii și menținerea stabilității sistemului.	Analiză comparativă, sinteză bibliografică	25 h
Elaborarea unei sinteze bibliografice privind tendințele actuale și direcțiile emergente de cercetare în utilizarea MARL pentru managementul energetic predictiv al microrețelelor, cu evidențierea avantajelor și limitărilor algoritmilor existenți, a mecanismelor de cooperare și coordonare între agenți și identificarea lacunelor și direcțiilor relevante pentru fundamentarea 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.] Gao, J., Li, Y., Wang, B., & Wu, H. (2023). Multi-microgrid collaborative optimization scheduling using an improved multi-agent soft actor-critic algorithm. <i>Energies</i>, 16(7), 3248. [2.] Ren, Z., You, M., Rivera, M., & Fang, Z. (2026). A digital-twin-aided safe multi-agent reinforcement learning framework for renewable-integrated residential energy management. <i>Energies</i>, 19(13), 3098. [3.] Myint, K. P. Y., Deansekeaw, An., Pahasa, J., Boonraksa, P., Boonraksa, T., & Marungsri, B. (2026). Multi-objective energy management optimization on grid-integrated microgrid using multi-agent deep reinforcement learning for enhanced system stability in HRES and BESS. <i>IEEE Access</i>, 14, 3668993. [4.] Li, Z., Wang, X., & Zhang, Y. (2026). Energy management for renewable power-to-ammonia in networked multi-energy microgrids: A multi-agent Soft Actor-Critic approach. <i>International Journal of Hydrogen Energy</i>, 52(Pt B), 238-251. [5.] Huang, C., Wang, H., & Lin, J. (2025). Agent-based decentralized energy management of EV charging station with solar photovoltaics via multi-agent reinforcement learning. <i>arXiv preprint arXiv:2505.18750</i>. [6.] Wang, L., Zhang, T., & Liu, J. (2026). A digital twin-based multi-agent reinforcement learning framework for vehicle-to-grid coordination. In <i>Proceedings of the International Conference on Algorithms and Architectures for Parallel Processing (ICA3PP 2025)</i> (pp. 520-535). Springer. [7.] Sutton, R. S., & Barto, A. G. (2018). <i>Reinforcement learning: An introduction</i> (2nd ed.). MIT Press. [8.] Lowe, R., Wu, Y., Tamar, A., Harb, J., Abbeel, P., & Mordatch, I. (2017). Multi-agent actor-critic for mixed cooperative-competitive environments. <i>Advances in Neural Information Processing Systems (NeurIPS 2017)</i>, 30, 6379-6390. [9.] Salazar-Pena, N., Tabares, A., & Gonzalez-Mancera, A. (2026). Harnessing implicit cooperation: A multi-agent reinforcement learning approach towards decentralized local energy markets. <i>arXiv preprint arXiv:2602.16062</i>. [10.] Liu, C., & Li, D. (2023). Multi-agent proximal policy optimization via non-fixed value clipping. In <i>Proceedings of the 12th Data Driven Control and Learning Systems Conference (DDCLS 2023)</i> (pp. 1684-1688). IEEE. [11.] Sunehag, P., Lever, G., Gruslys, A., Driessche, W. M., Tuyls, K., & Graepel, T. (2017). Value-decomposition networks for cooperative multi-agent learning. <i>arXiv preprint arXiv:1706.05296</i>. [12.] Michailidis, P., Michailidis, I., & Kosmatopoulos, E. (2025). Reinforcement learning for electric vehicle charging management: Theory and applications. <i>Energies</i>, 18(19), 6124. [13.] Korkas, C. D., Tsaknakis, C. D., Kapoutsis, A. C., & Kosmatopoulos, E. (2024). Distributed and multi-agent reinforcement learning framework for optimal electric vehicle charging scheduling. <i>Energies</i>, 17(11), 2643. [14.] 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. [15.] Zhang, J., Che, L., & Shahidepour, M. (2023). Distributed training and distributed execution based Stackelberg multi-agent reinforcement learning for EV charging scheduling. <i>IEEE Transactions on Smart Grid</i>, 14(5), 3912-3925.		

[16.] 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. *IEEE Transactions on Smart Grid*, 14(1), 559-571.

[17.] 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. *IEEE Transactions on Smart Grid*, 13(6), 4873-4886.

[18.] Rodriguez, M., Smith, T., & Johnson, K. (2024). Context-aware multi-agent coordination for smart grid optimization using attention mechanisms. *IEEE Transactions on Industrial Informatics*, 20(4), 5234-5245.

[19.] 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. *Applied Energy*, 353(Pt A), 122041.

[20.] 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. *Applied Energy*, 380, 125039.

[21.] 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.

[22.] Li, S., Hu, W., Cao, D., Zhang, Z., Huang, Q., Chen, Z., & Chen, F. (2024). Physics-informed multi-agent deep reinforcement learning enabled distributed voltage control for active distribution network using PV inverters. *International Journal of Electrical Power & Energy Systems*, 155(Pt A), 109641.

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 modelarea, optimizarea și controlul distribuit al sistemelor complexe, precum și utilizarea metodelor de **Reinforcement Learning (RL)** și **Multi-Agent Reinforcement Learning (MARL)** pentru soluționarea problemelor de decizie, coordonare și management energetic în microrețele. Tematica valorifică rezultate recente privind utilizarea algoritmilor multi-agent pentru optimizarea colaborativă, managementul energetic descentralizat și coordonarea subsistemelor energetice distribuite. Conținuturile sunt corelate cu preocupările comunității științifice și profesionale reflectate în literatura internațională de specialitate, inclusiv în publicații **IEEE**, privind dezvoltarea algoritmilor MARL, managementul microrețelilor cu surse regenerabile și sisteme de stocare, încărcarea inteligentă și coordonată a vehiculelor electrice, strategiile Vehicle-to-Grid (V2G), controlul distribuit al tensiunii și optimizarea funcționării sistemelor energetice inteligente. Conținuturile disciplinei răspund, de asemenea, cerințelor mediului economic și ale angajatorilor din domeniile sistemelor energetice inteligente, automatizărilor, inteligenței artificiale, microrețelilor, surselor regenerabile, stocării energiei și mobilității electrice, prin dezvoltarea capacității de analiză și evaluare a algoritmilor avansați pentru optimizarea, coordonarea și controlul sistemelor complexe și distribuite. Disciplina contribuie la dezvoltarea competențelor necesare abordării sistemice și interdisciplinare a problemelor complexe de management energetic și la fundamentarea unei cercetări doctorale originale privind **algoritmii MARL pentru managementul energetic predictiv în microrețele**, creând premise pentru dezvoltarea unor soluții avansate de control și optimizare și pentru valorificarea rezultatelor cercetării în comunitatea științifică și în mediul economic.

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 fundamentele Reinforcement Learning (RL), arhitecturile și algoritmii Multi-Agent Reinforcement Learning (MARL) și aplicarea acestora în managementul energetic predictiv al microrețelilor; capacitatea de identificare, selectare, analiză critică și sinteză a literaturii științifice de specialitate; capacitatea de analiză comparativă a algoritmilor MARL, a mecanismelor de cooperare și coordonare între agenți și a strategiilor de instruire și execuție centralizată sau distribuită; utilizarea adecvată a terminologiei științifice specifice domeniului; capacitatea de identificare și argumentare a avantajelor, limitărilor și lacunelor soluțiilor existente; fundamentarea științifică a cadrului metodologic și a direcției proprii de cercetare privind utilizarea algoritmilor MARL pentru managementul energetic predictiv al microrețelilor.	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 Reinforcement Learning (RL), Multi-Agent Reinforcement Learning (MARL) și aplicațiile acestora în managementul energetic al microrețelilor;			

- cunoașterea principiilor fundamentale, arhitecturilor și principalelor categorii de algoritmi MARL, precum și a mecanismelor de cooperare și coordonare între agenți;
- realizarea unei analize critice și a unei sinteze bibliografice privind utilizarea algoritmilor MARL pentru managementul energetic predictiv al microrețelelor, fundamentată pe surse științifice actuale și relevante;
- compararea și argumentarea adecvării unor algoritmi și strategii MARL pentru probleme de management energetic, integrarea surselor regenerabile, sistemelor de stocare și vehiculelor electrice;
- identificarea limitărilor soluțiilor existente și a unor lacune de cercetare relevante și fundamentarea unei direcții proprii de cercetare privind utilizarea algoritmilor MARL pentru managementul energetic predictiv în microrețele;
- 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



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 2 (Dezvoltarea unui algoritm distribuit MARL bazat pe mecanisme de atenție (MA-SAC) pentru planificarea energetică)						
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 arhitecturile și algoritmi de Multi-Agent Reinforcement Learning (MARL), cu accent pe metodele distribuite, algoritmi Soft Actor-Critic și mecanismele de atenție, în vederea fundamentării cadrului conceptual și metodologic pentru dezvoltarea unui algoritm MA-SAC destinat planificării energetice și definirii direcției proprii de cercetare doctorală în domeniul Ingineriei sistemelor.
6.2 Obiectivele specifice	- aprofundarea cunoștințelor privind fundamentele Reinforcement Learning (RL) și Multi-Agent Reinforcement Learning (MARL), arhitecturile multi-agent și mecanismele de învățare, cooperare și coordonare distribuită utilizate pentru soluționarea problemelor complexe de decizie și planificare; - dezvoltarea capacității de documentare științifică utilizând baze de date internaționale și surse bibliografice relevante privind algoritmi MARL și aplicarea acestora în planificarea și managementul energetic; - formarea competențelor de analiză critică, comparare și evaluare a arhitecturilor și algoritmilor MARL, cu accent pe metodele actor-critic, Soft Actor-Critic (SAC) și strategiile de antrenare și execuție centralizată sau distribuită; - aprofundarea mecanismelor de atenție utilizate în sistemele multi-agent pentru selectarea și ponderarea informațiilor relevante și îmbunătățirea cooperării, coordonării și procesului decizional între agenți; - identificarea tendințelor actuale, a avantajelor și limitărilor soluțiilor existente și a cerințelor metodologice relevante pentru dezvoltarea și evaluarea unui algoritm distribuit MA-SAC destinat planificării energetice; - 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 dezvoltarea unui algoritm distribuit MARL bazat pe mecanisme de atenție pentru planificarea energetică.

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 fundamentele Reinforcement Learning (RL) și Multi-Agent Reinforcement Learning (MARL), arhitecturile multi-agent și mecanismele de învățare, cooperare și coordonare între agenți; - cunoaște principiile și particularitățile arhitecturilor actor-critic și ale algoritmilor Soft Actor-Critic (SAC) utilizați în sisteme multi-agent și distribuite; - cunoaște principiile mecanismelor de atenție și rolul acestora în selectarea și ponderarea informațiilor relevante și în coordonarea procesului decizional al agenților; - înțelege metodele de utilizare a algoritmilor MARL distribuiți pentru planificarea și managementul energetic al sistemelor complexe, precum și criteriile de analiză și evaluare a performanțelor acestora.
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 algoritmi MARL distribuiți, mecanismele de atenție și aplicațiile acestora în planificarea energetică; - să analizeze comparativ arhitecturile și algoritmi MARL, cu accent pe metodele actor-critic și Soft Actor-Critic, evidențiind avantajele, limitările și adecvarea acestora pentru probleme de planificare energetică; - să analizeze mecanismele de cooperare, coordonare și schimb de informații între agenți și să evalueze rolul mecanismelor de atenție în îmbunătățirea procesului decizional distribuit; - să analizeze și să argumenteze opțiunile metodologice privind arhitectura, mecanismele de atenție, strategia de antrenare și execuție și criteriile de evaluare relevante pentru dezvoltarea unui algoritm distribuit MA-SAC; - să identifice limitările soluțiilor existente și lacunele de cercetare și să fundamenteze cadrul conceptual și metodologic pentru dezvoltarea unui algoritm MA-SAC destinat planificării energetice.
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 privind algoritmi MARL și planificarea energetică, cu respectarea principiilor eticii și integrității academice; - își asumă responsabilitatea pentru selectarea și fundamentarea arhitecturilor, algoritmilor și mecanismelor de coordonare relevante pentru obiectivele cercetării doctorale; - argumentează în mod independent alegerea mecanismelor de atenție, a arhitecturii MA-SAC și a strategiilor de antrenare și execuție adecvate problemei de planificare energetică; - dezvoltă în mod autonom cadrul conceptual și metodologic al cercetării și își asumă responsabilitatea pentru fundamentarea științifică a direcției proprii de cercetare privind dezvoltarea unui algoritm distribuit MARL

8. Conținuturi

8.2 Studiu individual	Metode de predare	Observații
Studierea bibliografiei fundamentale privind principiile Reinforcement Learning și Multi-Agent Reinforcement Learning (MARL), arhitecturile multi-agent și metodele de învățare și coordonare distribuită, cu accent pe algoritmi actor-critic și Soft Actor-Critic utilizați pentru soluționarea problemelor complexe de decizie, optimizare și planificare energetică.	Studiu individual, analiză bibliografică	45 h
Documentarea în baze de date științifice privind algoritmi MARL distribuiți și integrarea mecanismelor de atenție în arhitecturile multi-agent, cu accent pe metodele de selecție și ponderare a informațiilor relevante, mecanismele de cooperare și coordonare între agenți și strategiile de antrenare și execuție centralizată sau distribuită.	Documentare în baze de date, analiză critică	25 h
Analiza critică și comparativă a literaturii privind algoritmi MARL utilizați pentru planificarea și managementul energetic al microgridurilor, cu evaluarea arhitecturilor actor-critic, a algoritmilor Multi-Agent Soft Actor-Critic (MA-SAC), a mecanismelor de atenție și a strategiilor de coordonare distribuită în condițiile integrării surselor regenerabile, sistemelor de stocare și sarcinilor flexibile.	Analiză comparativă, sinteză bibliografică	25 h
Elaborarea unei sinteze bibliografice privind tendințele actuale și direcțiile emergente de cercetare referitoare la utilizarea algoritmilor MARL distribuiți bazați pe mecanisme de atenție pentru planificarea energetică, cu identificarea avantajelor și limitărilor soluțiilor existente, a cerințelor de proiectare și evaluare a unui algoritm MA-SAC 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.] Burgaud, V., Laraki, M. H., Bossard, J., & Ploix, S. (2026). Reinforcement learning vs. model-based control in electric vehicle charging microgrids. <i>Control Engineering Practice</i>, 168, 106421. https://www.sciencedirect.com/science/article/pii/S0967066126001346 [2.] Fan, J., Huang, C., & Wang, H. (2025). Agent-based decentralized energy management of EV charging station with solar photovoltaics via multi-agent reinforcement learning. <i>arXiv preprint arXiv:2505.18750</i>. https://arxiv.org/abs/2505.18750 [3.] Gao, J., Li, Y., Wang, B., & Wu, H. (2023). Multi-microgrid collaborative optimization scheduling using an improved multi-agent soft actor-critic algorithm. <i>Energies</i>, 16(7), 3248. https://www.mdpi.com/1996-1073/16/7/3248 [4.] 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 [5.] 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 [6.] Korkas, C. D., Tsaknakis, C. D., Kapoutsis, A. C., & Kosmatopoulos, E. (2024). Distributed and multi-agent reinforcement learning framework for optimal electric vehicle charging scheduling. <i>Energies</i>, 17(11), 2643. https://www.mdpi.com/1996-1073/17/11/2643 [7.] 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 [8.] Liu, C., & Li, D. (2023). Multi-agent proximal policy optimization via non-fixed value clipping. <i>Proceedings of the 12th Data Driven Control and Learning Systems Conference (DDCLS)</i>, 1684-1688. https://doi.org/10.1109/DDCLS58216.2023.10167264 [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. Link de identificare: https://scholar.google.com/scholar?q=%22Multi-agent+reinforcement+learning+for+electric+vehicle+charging+coordination+with+renewable+energy+integration%22 [10.] Lowe, R., Wu, Y., Tamar, A., Harb, J., Abbeel, P., & Mordatch, I. (2017). Multi-agent actor-critic for mixed cooperative-competitive environments. <i>Advances in Neural Information Processing Systems (NeurIPS 2017)</i>, 30, 6379-6390. https://proceedings.neurips.cc/paper/2017/file/68a9750337a418a86fe06c1991a1d64c-Abstract.html [11.] 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 [12.] Michailidis, P., Michailidis, I., & Kosmatopoulos, E. (2025). Reinforcement learning for electric vehicle charging		

- management: Theory and applications. *Energies*, 18(19), 6124. <https://www.mdpi.com/1996-1073/18/19/6124>
- [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://ieeexplore.ieee.org/document/11415591>
- [14.] Ren, Z., You, M., Rivera, M., & Fang, Z. (2026). A digital-twin-aided safe multi-agent reinforcement learning framework for renewable-integrated residential energy management. *Energies*, 19(13), 3098. <https://www.mdpi.com/1996-1073/19/13/3098>
- [15.] Rodriguez, M., Smith, T., & Johnson, K. (2024). Context-aware multi-agent coordination for smart grid optimization using attention mechanisms. *IEEE Transactions on Industrial Informatics*, 20(4), 5234-5245. Link de identificare: <https://scholar.google.com/scholar?q=%22Context-aware+multi-agent+coordination+for+smart+grid+optimization+using+attention+mechanisms%22>
- [16.] Salazar-Pena, N., Tabares, A., & Gonzalez-Mancera, A. (2026). Harnessing implicit cooperation: A multi-agent reinforcement learning approach towards decentralized local energy markets. *arXiv preprint arXiv:2602.16062*. <https://arxiv.org/abs/2602.16062>
- [17.] Salaorni, D., Bianchi, F., Restelli, M., & Trovò, F. (2025). A reinforcement learning approach for optimal control in microgrids. *arXiv preprint arXiv:2506.22995*. <https://arxiv.org/abs/2506.22995>
- [18.] Sunehag, P., Lever, G., Gruslys, A., Driessche, W. M., Tuyls, K., & Graepel, T. (2017). Value-decomposition networks for cooperative multi-agent learning. *arXiv preprint arXiv:1706.05296*. <https://arxiv.org/abs/1706.05296>
- [19.] Sutton, R. S., & Barto, A. G. (2018). *Reinforcement learning: An introduction* (2nd ed.). MIT Press. <https://mitpress.mit.edu/9780262039246/reinforcement-learning/>
- [20.] 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 & Energy Systems*, 380, 125039. <https://www.sciencedirect.com/science/article/pii/S0306261924024231>
- [21.] Tuchnitz, 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>
- [22.] Wang, R., & Smart, G. (2024). Reinforcement learning in microgrid energy management: Review, methods and prospects. *IET Smart Grid*, 7(4), 412-431. Link de identificare: <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. Link de identificare: <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 considering EV charging scheduling. *Proceedings of the 8th International Conference on Power Energy Systems and Applications (ICoPESA)*, 488-494. Link de identificare: <https://scholar.google.com/scholar?q=%22Intelligent+energy+management+method+of+EV+charging+station+with+photovoltaic+and+energy+storage+system+considering+EV+charging+scheduling%22>
- [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(5), 3912-3925. <https://ieeexplore.ieee.org/document/10233034/>

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 modelarea, optimizarea și controlul distribuit al sistemelor complexe, precum și utilizarea metodelor de Reinforcement Learning (RL) și Multi-Agent Reinforcement Learning (MARL) pentru soluționarea problemelor de decizie, coordonare și planificare energetică. Tematica disciplinei pune accent pe arhitecturile actor-critic, algoritmi Soft Actor-Critic (SAC), mecanismele de atenție și strategiile de învățare și execuție distribuită în sisteme multi-agent. Conținuturile sunt corelate cu preocupările comunității științifice și profesionale reflectate în literatura internațională de specialitate, inclusiv în publicații IEEE, privind dezvoltarea algoritmilor MARL, coordonarea distribuită a agenților, utilizarea mecanismelor de atenție și aplicarea metodelor de învățare prin întărire pentru optimizarea și managementul sistemelor energetice inteligente. Bibliografia include atât lucrări fundamentale privind RL și MARL, cât și cercetări privind metode actor-critic, învățarea cooperativă și coordonarea multi-agent. Conținuturile disciplinei răspund, de asemenea, cerințelor mediului economic și ale angajatorilor din domeniile sistemelor energetice inteligente, automatizărilor, inteligenței artificiale, microgridurilor, surselor regenerabile, stocării energiei și mobilității electrice, prin dezvoltarea capacității de analiză și evaluare a algoritmilor avansați pentru planificarea, optimizarea și coordonarea distribuită a sistemelor energetice. Caracterul aplicativ al tematicii este susținut de literatura privind utilizarea MARL pentru microgriduri, BESS, integrarea surselor regenerabile și managementul încărcării vehiculelor electrice. Disciplina contribuie la dezvoltarea competențelor necesare abordării sistemice și interdisciplinare a problemelor complexe de planificare energetică și la fundamentarea unei cercetări doctorale privind dezvoltarea unui algoritm distribuit MARL bazat pe mecanisme de atenție (MA-SAC), creând premise pentru proiectarea, evaluarea și validarea unor soluții avansate de decizie și coordonare în sisteme energetice complexe.

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 fundamentele Reinforcement Learning (RL), arhitecturile și algoritmii Multi-Agent Reinforcement Learning (MARL), cu accent pe metodele actor-critic, Soft Actor-Critic (SAC) și mecanismele de atenție; capacitatea de identificare, selectare, analiză critică și sinteză a literaturii științifice de specialitate; capacitatea de analiză comparativă a algoritmilor MARL, a mecanismelor de cooperare și coordonare între agenți și a strategiilor de antrenare și execuție centralizată sau distribuită; evaluarea rolului mecanismelor de atenție în procesul decizional multi-agent; utilizarea adecvată a terminologiei științifice specifice domeniului; identificarea și argumentarea avantajelor, limitărilor și lacunelor soluțiilor existente; fundamentarea științifică a cadrului conceptual și metodologic pentru dezvoltarea unui algoritm distribuit MA-SAC destinat planificării energetice.	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 Reinforcement Learning (RL), Multi-Agent Reinforcement Learning (MARL), algoritmii actor-critic și aplicațiile acestora în planificarea energetică; - cunoașterea principiilor și arhitecturilor MARL, cu accent pe algoritmii Soft Actor-Critic (SAC), mecanismele de cooperare și coordonare între agenți și strategiile de antrenare și execuție centralizată sau distribuită; - realizarea unei analize critice și a unei sinteze bibliografice privind algoritmii MARL distribuiți și utilizarea mecanismelor de atenție în probleme de planificare și management energetic, fundamentată pe surse științifice actuale și relevante; - compararea și argumentarea adecvării algoritmilor, mecanismelor de atenție și strategiilor de coordonare distribuită pentru dezvoltarea unei soluții MA-SAC destinate planificării energetice; - identificarea avantajelor, limitărilor și lacunelor soluțiilor existente și fundamentarea cadrului conceptual și metodologic pentru dezvoltarea unui algoritm distribuit MARL bazat pe mecanisme de atenție; - 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