



UNIVERSITATEA DE MEDICINĂ,
FARMACIE, ȘTIINȚE ȘI TEHNOLOGIE
"GEORGE EMIL PALADE"
DIN TÂRGU MUREȘ

Rezumat Raport Științific și Tehnic rRST

Etapa II
Anul 2020

**Definire și concepere sistem multiagent pentru detecția
predictivă a defectelor**

Cod proiect: COFUND-CHIST-ERA-SOON

Nr contract: 101/ 17.04.2019

Titlul proiectului (în română): *Rețea Socială de Dispozitive Inteligente*

Titlul proiectului (în engleză): *Social Network of Machines*

Acronimul proiectului: *SOON*

*Universitatea de Medicină, Farmacie, Științe și Tehnologie
"George Emil Palade" din Târgu Mureș (UMFST)*

Pagina web a proiectului UMFST: *<https://soon.umfst.ro>*

Durata contractului: *17/04/2019 - 28/04/2022 (36 de luni)*

Data începerii etapei II: *03/12/2019*

Data raportării etapei I: *02/12/2020*

Cuprins

1. Obiectivele Etapei II: anul 2020	3
1.1. Context. Aspecte preliminare	3
1.2. Obiectivele aferente anului 2020	5
1.3. Activitățile specifice ale etapei	6
2. Rezumatul Etapei II	8
3. Descrierea științifică și tehnică	13
3.1. Aspecte preliminare	13
3.2. Specificații industriale model de integrare date	14
3.3. Sinteză scenarii de mentenanță predictivă	15
3.4. Specificații și arhitectură sistem social multiagent	20
3.5. Paradigme și mentenanța predictivă	27
4. Concluzii	29
5. Bibliografie	30

1. Obiectivele Etapei II: anul 2020

1.1. Context. Aspecte preliminare

Documentul de față sintetizează activitățile principale și rezultatele aferente Etapei a II-a de desfășurare a proiectului. Una dintre noutățile aduse de Industria 4.0 constă în adoptarea tehnologiilor “smart” la toate nivelele producției industriale. În abordările actuale de ultimă oră, inteligența, dacă este implementată, este localizată la nivel individual, iar entitățile eterogene inteligente de multe ori nu pot comunica și coopera eficient chiar dacă au o localizare apropiată. Principala motivație a cercetării noastre rezidă în faptul că, dacă vrem să creăm un Internet autentic “*a tot*” ceea ce reunește procese, date, lucruri și oameni, atunci, toate aceste entități trebuie să fie conectate și să urmeze o paradigmă partajată și ușor de înțeles.

În acest proiect, propunem o paradigmă holistică multi-agent care cuprinde mașini, procese și oameni. Prezența operatorilor umani este esențială, ca sursă a expertizei tehnice, ce va fi transmisă agenților software, iar aceștia prin accesul la numeroase surse de date, prin intermediul algoritmilor de învățare profundă și de extragere a unor detalii și caracteristici, vor furniza informații noi, esențiale, altfel dificil de obținut operatorilor umani. Agenții vor lua decizii pornind de la datele colectate, în urma fuziunii și analizei unor cantități mari eterogene de date produse în timp real de senzori (de vibrații, de temperatură etc.), de sistemele de automatizare și informare (cum ar fi sistemele de planificare și supervizare a resurselor întreprinderii), respectiv de operatorii umani.

Scopul principal al proiectului constă în identificarea și propunerea unor soluții inovative pentru optimizarea proceselor de fabricație prin metode inteligente de mentenanță predictivă. Modul de rezolvare a acestei probleme în cadrul proiectului SOON pleacă de la un set de scenarii de mentenanță predictivă stabilite în colaborare cu trei companii industriale (din Slovacia, Spania și Elveția). Alegerea acestor trei parteneri industriali, cu un profil industrial complet diferit, s-a bazat pe creșterea generalității abordării noastre și pe dovedirea caracterului adecvat pentru o diversitate mai mare a proceselor industriale de fabricație. Intenționăm să demonstrăm că introducerea principiilor specifice Industriei 4.0, combinată cu îmbunătățirile recente ale învățării automate, și aplicarea unei arhitecturi bazată pe un sistem social multi-agent pot conduce în final la obținerea unei inovații semnificative în optimizarea și modelarea proceselor industriale.

În Etapa a II-a de raportare a proiectului, consorțiul format din trei universități, un institut de cercetare al unei academii și trei companii industriale cu profil de producție distinct (producție mașini unelte, industrie siderurgică, reciclare și producție mase plastice) din diferite țări europene s-a focusat pe crearea cadrului de implementare a propunerii SOON.

Consortiul de implementare a proiectului SOON este compus din următoarele entități:

- Universitatea de Științe Aplicate și Arte Elveția de Vest (HES-SO) din Elveția, coordonator de proiect;
- Academia Slovacă de Științe (SAV) din Slovacia;
- Universitatea din Oviedo (UNIOVI) din Spania;
- Universitatea de Medicină, Farmacie, Științe și Tehnologie „George Emil Palade” din Târgu Mureș (UMFST);
- Compania Tornos SA (Tornos) din Elveția, partener industrial;
- MAT-obaly, s.r.o. (MAT) din Slovacia, partener industrial;
- ArcelorMittal (AMI3) din Spania, partener industrial.

Nomenclator de acronime și abrevieri

ABT	Algoritm backtracking asincron (Asynchronous Backtracking)
AP	Automatizarea producției (Production Automation)
CPPS	Sisteme ciber-fizice de producție (Cyber Physical Production System)
CRM	Sistem pentru Managementul relațiilor cu clienții (Customer Relationship Management)
CSP	Problemă de satisfacere a constrângerilor (Constraint Satisfaction Problem)
DDS	Interfață de comunicare de stocare a datelor distribuită (Distributed Data Storage Communication Interface)
ERP	Sistem pentru planificarea resurselor întreprinderii (Enterprise Resource)
HPC	Sistem de calcul de înaltă performanță (High-Performance Computing)
HSM	Laminare la cald (Hot Strip Mill)
IA	Inteligență artificială (Artificial Intelligence)
ICPS	Internetul sistemelor ciber-fizice (Internet Cyber Physical System)
IIC	Consortiul Internetului Industrial (Industrial Internet Consortium)
IIoT	Internetul industrial al lucrurilor (Industrial Internet of Things)
IIRA	Arhitectura de referință pentru Internet industrial (Industrial Internet Reference Architecture)
IoE	Internetul tuturor lucrurilor (Internet of Everything)
IPA	Arhitectura piramidei informaționale (Information Pyramid Architectures)
KD	Bază de date de cunoștințe (Knowledge database)
KE	Schimb de cunoștințe (Knowledge exchange)
LTS	Depozitare pe termen lung (Long-term Storage)
OAI	Interfață agent-operator (Operator-Agent Interface)
OEE	Efectivitatea generală a echipamentului (Overall Equipment Effectiveness)
PdM	Mentenanță predictivă (Predictive Maintenance)
PLC	Controler logic programabil (Programmable Logic Controller)

RAMI	Modelul arhitecturii de referință pentru Industria 4.0 (Reference Architecture Model Industry 4.0)
RDE	Schimb de date brute (Raw Data Exchange)
RUL	durata de viață utilă rămasă a uneltei (remaining useful lifetime of the tool)
RWM	Laminor de sârmă (Rod Wire Mill)
SBC	Calculator mono-placă (Single-Board Computer)
SCM	Sistem pentru Managementul lanțului de aprovizionare (Supply Chain Management)
SMA	Sistem multiagent (Multi-agent System)
SoC	Sistem într-o capsulă (System-on-a-Chip)
TEEP	Eficiența totală a echipamentului (Total Effective Equipment Performance)
TIC	Tehnologia Informației și Comunicării
VI	Instrumentele de vizualizare

1.2. Obiectivele aferente anului 2020

Obiectivul general al proiectului SOON este de a investiga impactul utilizării agenților sociali autonomi inteligenți pentru optimizarea proceselor de producție industrială în cadrul Industriei 4.0 din perspectiva menținerii în funcțiune la parametri nominali și evitarea întreruperilor prin aplicarea unor măsuri adecvate de mentenanță predictivă. Soluția propusă constă în principal în anticiparea și depistarea timpurie a apariției defecțiunilor, identificarea naturii defecțiunilor, respectiv localizarea acestora.

Obiectivul specific etapei I, cu realizarea planificată în întregime în această etapă, a fost realizat cu succes. Acesta a constat în principal în Identificarea nevoilor particulare ale mediului industrial reprezentat prin intermediul partenerilor industriali și a cerințelor aferente uneltelor ce vor fi dezvoltate în acest proiect, respectiv care vor răspunde provocărilor prin prisma conceptului de Industrie 4.0.

Obiectivele specifice etapei II constau în următoarele:

- Analiza cerințelor, sinteza specificațiilor și proiectarea arhitecturii agenților sociali și a sistemului multiagent cooperativ ce înglobează mașini, senzori, alături de operatori umani în scopul implementării soluției de sistem ciber-fizic pentru asigurarea mentenanței predictive; conceperea și dezvoltarea de ontologii aferente soluției propuse de proiect; conceperea framework-ului de integrare; design-ul interfațării dispozitivelor inteligente și a interfaței om-mașină.
- Implementarea platformei de testare și evaluare soluției IIoT/IIoE pentru mentenanța predictivă.
- Tratarea diferitor aspecte referitoare la datele ce vor fi disponibile în cadrul proiectului. Aspecte referitoare la: descrierea datelor și integrarea datelor.
- Conceperea scenariilor principale de mentenanță predictivă. Conceperea, testarea și evaluarea de algoritmi de mentenanță predictivă, cu precădere axați pe detecția defectelor apelând la tehnici de IA;

- Organizarea unui management eficient al proiectului. Actualizarea strategiei de diseminare a rezultatelor și comunicarea cu stakeholderii interesați. Toate acestea au presupus luarea în considerare a contextului actual pandemic cu virusul SARS-CoV-2.

1.3. Activitățile specifice ale etapei

În **conformitate totală cu Planul de Realizare al Proiectului**, în cadrul Etapei a II-a au fost implementate două categorii de activități: unele aflate în derulare din Etapa I-a, respectiv unele care au început în această etapă.

Act 2.1 Dezvoltare framework de integrare [Continuarea Act 1.5. din Etapa I; va continua în Etapa III] (realizat cf. plan de realizare)

Activitățile aferente sarcinii de analiză a cerințelor și proiectarea framework-ului de integrare au presupus pregătirea specificațiilor de integrare în concordanță cu scenariile de mentenanță predictivă. Cerințele sintetizate depind într-o măsură semnificativă de scenariile implementate, mașinile disponibile și varietatea crescută a datelor disponibile. Printre principiile fundamentale pe care se bazează soluția propusă se numără scalabilitatea și extensibilitatea, care vor asigura independența soluției propuse de ordinul de mărime al platformei industriale.

Taskurile/sarcinile particulare ce țin de integrarea diferitelor module software sunt rezultate din pachetele de lucru (PL), PL3 și PL4. Pentru dezvoltarea prototipului sistemului sunt considerate platforme de tehnologii de vârf orientate spre gestionarea procesărilor distribuite, care permit funcționalități avansate pentru integrarea IoT, gestionarea unui volum mare de date, extragerea caracteristicilor și învățarea automată.

Printre taskurile particulare ale acestei activități se numără experimentarea și evaluarea platformei FIWARE cu diferite module integrate, cum ar fi Orion Context Broker, Cygnus, și stocările de date NoSQL MongoDB și InfluxDB pentru serii de timp.

Act 2.2. Specificare model de integrare a datelor. [activitate începută în Etapa II](realizat cf. plan de realizare).

Această activitate include printre altele identificarea surselor de date pentru scenariile stabilite, proiectarea unei infrastructuri care suportă Big Data și stabilirea modului în care datele sunt prelucrate și stocate. Un aspect tratat constă în obținerea unei descrieri a modelului de date care va fi implementat într-o infrastructură de tip cloud, cum ar fi Azure de la Microsoft și/sau Apache Storm Cluster a căror adoptare este în curs de evaluare.

Act 2.3. *Conceperea arhitecturii agenților sociali.* [Continuarea Act 1.2. din Etapa I](realizat cf. plan de realizare)

Activitatea a constat în demararea proiectării ontologiei și a arhitecturii sistemului multiagent luând în considerare rolul și maparea agenților (la nivel de mașină, secție de producție, fabrică, companie), performanțele vizate, capacitățile, starea utilajelor (istoricul defectărilor, starea curentă, etc.) și a capacităților sociale.

Act 2.4. *Implementare model și arhitectură soluție rețea socială multiagent.* [activitate începută în Etapa II; cu continuare în Etapa III] (realizat cf. plan de realizare)

Această activitate constă în proiectarea profilurilor agenților și a relațiilor sociale dintre agenți. Spre exemplificare, ca relații sociale pot fi menționate cele de: ajutor, asistență, prietenie, urmărire etc. Activitatea se referă la proiectarea modului în care rețeaua socială a mașinilor este creată, cum se realizează comunicarea și evoluția (de exemplu, o mașină nouă este adăugată sau îndepărtată din fluxul de producție), definirea rolurilor pe care trebuie să le preia agenții, interacțiunea lor și identificarea relațiilor de ierarhie. Printre altele a presupus proiectarea mediului de colaborare în timp real bazat pe cloud.

Act 2.5. *Explorare și concepere algoritmi de mentenanță bazați pe inteligența artificială (IA).* [Continuarea Act 1.3. din Etapa I; va continua în Etapa III] (realizat cf. plan de realizare)

A avut loc demararea analizei și specificarea scenariilor de mentenanță predictivă prin analize exploratorii cu partenerii industriali pentru identificarea celor mai semnificative cazuri de defectare cu accent pe predicția duratei întreruperilor ca urmare a defectărilor și a predicției defectării senzorilor.

Există diferite tipuri de date care vor fi utilizate, într-o primă fază fiind vizate seriile de timp. Pe baza acestora au fost studiate și testate diverse metode de regresie (liniară, neliniară, liniară multiplă și adaptivă) și rețele neuronale recurente, urmărindu-se în ce măsură acestea corespund necesităților. De asemenea au fost studiate și testate numeroase metode de clasificare. Activitatea va continua în Etapa III. Algoritmii care vor fi în final proiectați, vor fi implementați, testați și evaluați, de exemplu, aplicând validarea încrucișată. Achiziția de date necesară testării și evaluării algoritmilor este o fază a acestei activități.

Act 2.6. *Dezvoltare interfațare dispozitive inteligente și interfață om-mașină.* [activitate începută în Etapa II; cu continuare în Etapa III] (realizat cf. plan de realizare)

Această activitate se concentrează în mod special pe definirea și implementarea interfețelor utilizator (IU) pentru asigurarea unei interoperări sigure și eficiente cu senzorii, între mașini, agenți și operatori umani. În acest context esențială este luarea în considerare a eterogenității datelor.

Act 2.7. Testare și evaluare soluție integrată mentenanță predictivă. [activitate începută în Etapa II; cu continuare în Etapa III](realizat cf. plan de realizare)

În această etapă a fost realizată o analiză ce a avut la bază un studiu bibliografic comprehensiv referitor la Indicatorii de performanță (IP; en: Key Performance Indicators-KPI) ce pot fi utilizați de exemplu pentru măsurarea productivității și eficienței în procesele de producție. Au fost studiate printre altele Eficiența generală a echipamentelor (OEE), și Eficiența totală a echipamentelor (TEEP). Atât OEE cât și TEEP sunt indicatori cu o largă utilizare.

Act 2.8. Managementul proiectului și diseminare [Continuarea Act 1.4 din Etapa I; va continua în Etapa III] (realizat cf. plan de realizare)

Această activitate a constat în realizarea sarcinilor necesare asigurării managementului proiectului, activităților de raportare, de diseminare și de vizibilitate. Un pas în vederea asigurării vizibilității a constat în actualizarea portalului web a proiectului ce ține de partenerul din țară, respectiv popularea acestuia cu informațiile specifice etapei actuale. A fost efectuat un studiu referitor la elaborarea și planificarea strategiei de diseminare pe tot parcursul derulării proiectului ținând cont de contextul pandemic actual cu virusul Covid-19 a cărei evoluție și consecințe nu se pot estima.

Act 2.9. Implementare algoritmi pentru detecția defectelor apelând la tehnici de IA. [activitate începută în Etapa II; cu continuare în Etapa III](realizat cf. plan de realizare)

În cadrul acestei activități se urmărește proiectarea și implementarea unor algoritmi de detectare automată a defecțiunilor. Acesta vizează într-o primă etapă, pregătirea datelor pentru învățarea automată. Acest proces în funcție de caracteristicile datelor poate să presupună printre altele condiționarea, filtrarea, vizualizarea științifică și etichetarea. În continuare procesul fiind urmat de testare, evaluare și validare. Scopul principal al acestei activități constă în găsirea răspunsului la ipoteza: dacă detectarea automată a defecțiunilor senzorilor îmbunătățește performanțele generale măsurate cu ajutorul IP.

2. Rezumatul Etapei II

2.1. Activități specifice de implementare a propunerii SOON desfășurate în Etapa II

Etapa II a inclus diverse activități de implementare a proiectului (prezentate în secțiunea 1.3.) care au fost desfășurate cu succes conform planului de realizare. Echipa UMFST a investit un efort deosebit în sarcina de elaborare cu succes a arhitecturii IT a soluției SOON propuse .

2.2. Colaborarea cu partenerii de proiect SOON

A fost menținută o colaborare strânsă cu partenerii de proiect SOON, atât cei din mediul universitar cât și cei industriali. Lunar au fost organizate videoconferințe generale la care au participat toți partenerii din proiect. Cu aceste ocazii au fost prezentate rapoartele de progres de partea tuturor partenerilor. În funcție de necesități au fost stabilite întâlniri de discuții bilaterale pe teme de interes particulare.

2.3. Colaborarea pe linie științifică și cercetare dintre proiectele SOON și FIREMAN

Colaborarea științifică între proiectele SOON și FIREMAN (*Framework for the Identification of Rare Events via Machine learning and IoT Networks*), inițiată în prima etapă a proiectului, a fost întărită. Această colaborare va fi continuată și aprofundată în Etapa a III-a de implementare a proiectului. Se vor organiza întâlniri bilaterale între cele două proiecte. Când va fi necesar se vor stabili întâlniri focusate pe anumite subiecte de discuție (cercetări particulare, schimb de expertiză) la care vor participa grupurile de lucru interesate. Motivația generală a acestei colaborări constă în complementaritatea existentă între cele două proiecte, ce sugerează obținerea în sfera cercetării a unor beneficii de ambele părți.

2.4. Workshop-ul Internațional Smart Technologies in Industry 4.0 (RATIONALITY)

Proiectele SOON și FIREMAN au organizat în cadrul celei de a 14-a ediții a Conferinței Internaționale *International Conference Interdisciplinarity in Engineering (INTER-ENG 2020*, <https://inter-eng.umfst.ro/2020>, <https://www.facebook.com/InterEng>) Workshop-ul 1st *International Workshop on Smart Technologies in Industry 4.0 (RATIONALITY)*, ce s-a desfășurat în data de 10 Octombrie 2020.

(<https://inter-eng.umfst.ro/2020/index.php?page=workshop&action=rationality>).

Inițiativa și contribuția principală la organizarea Workshop-ului a avut-o echipa UMFST prin rolul de gazdă al evenimentului și organizator principal. Desfășurarea evenimentului a avut loc online, locația virtuală fiind pe platforma Microsoft Teams a UMFST.

Topicul general al conferinței Inter-Eng din anul 2020 a fost “Viitorul digital industrial al Europei: o viziune largă a conceptului Industry 4.0 dincolo de producția propriu-zisă” (“Europe's future is digital: a broad vision of the Industry 4.0 concept beyond direct manufacturing in the company”).

Topicul particular abordat: „Integrarea conceptelor Industriei 4.0 în mediul de producție care formează un lanț valoric complet de la furnizori la clienți și toate funcțiile și serviciile de afaceri ale întreprinderii” („Integration of the concepts of Industry 4.0 in the production environment which form a complete value chain from providers to customers and all enterprise’s business functions and services”).

Evenimentul a fost organizat în sistem de *videoconferință* pe platforma Microsoft Teams, având centrul de coordonare și desfășurare astfel:

Locație virtuală: UMFST, Nicolae Iorga st. No. 1, Târgu Mureș, Mureș

Online: Room Workshop SOON - FIREMAN

<https://inter-eng.umfst.ro/2020/index.php?page=workshop&action=rationality>

Workshopul RATIONALITY și-a propus să reunească în același forum cercetători ai unor proiecte europene de cercetare finanțate în cadrul programului CHIST-ERA susținut de programul Future and Emerging Technologies (FET) al Uniunii Europene prin intermediul sistemului de finanțare ERA-NET Cofund, ORIZONT 2020.

La această ediție a workshop-ului au participat cercetători implicați în implementarea celor două proiecte CHIST-ERA aflate în relație de colaborare, și anume SOON și FIREMAN, și care au prezentat rezultatele cercetărilor obținute, respectiv rapoartele lor de progres. De asemenea s-au discutat probleme deschise de cercetare care ar putea implica transferul de cunoștințe sau chiar colaborarea științifică. În cele din urmă au fost analizate posibilitățile și oportunitățile viitoare de colaborare aprofundată între cele două proiecte.

2.5. Diseminare, comunicare, participare la conferințe

2.5.1. Comunicarea rezultatelor și diseminare

Cu scop de diseminare, în cadrul Workshop-ului RATIONALITY, echipa UMFST a realizat prezentarea intitulată: *Physical Model for Electric Drive Equipped Production Unit Simulation with Edge Computing Based Monitoring Technology* [Gli20a]. Toți autorii prezentării fac parte din echipa UMFST de implementare a proiectului. Una dintre obiectivele prezentării a constat în diseminarea unor rezultate parțiale ale cercetării obținute în cadrul proiectului SOON care urmează a fi extinse, diseminate și publicate.

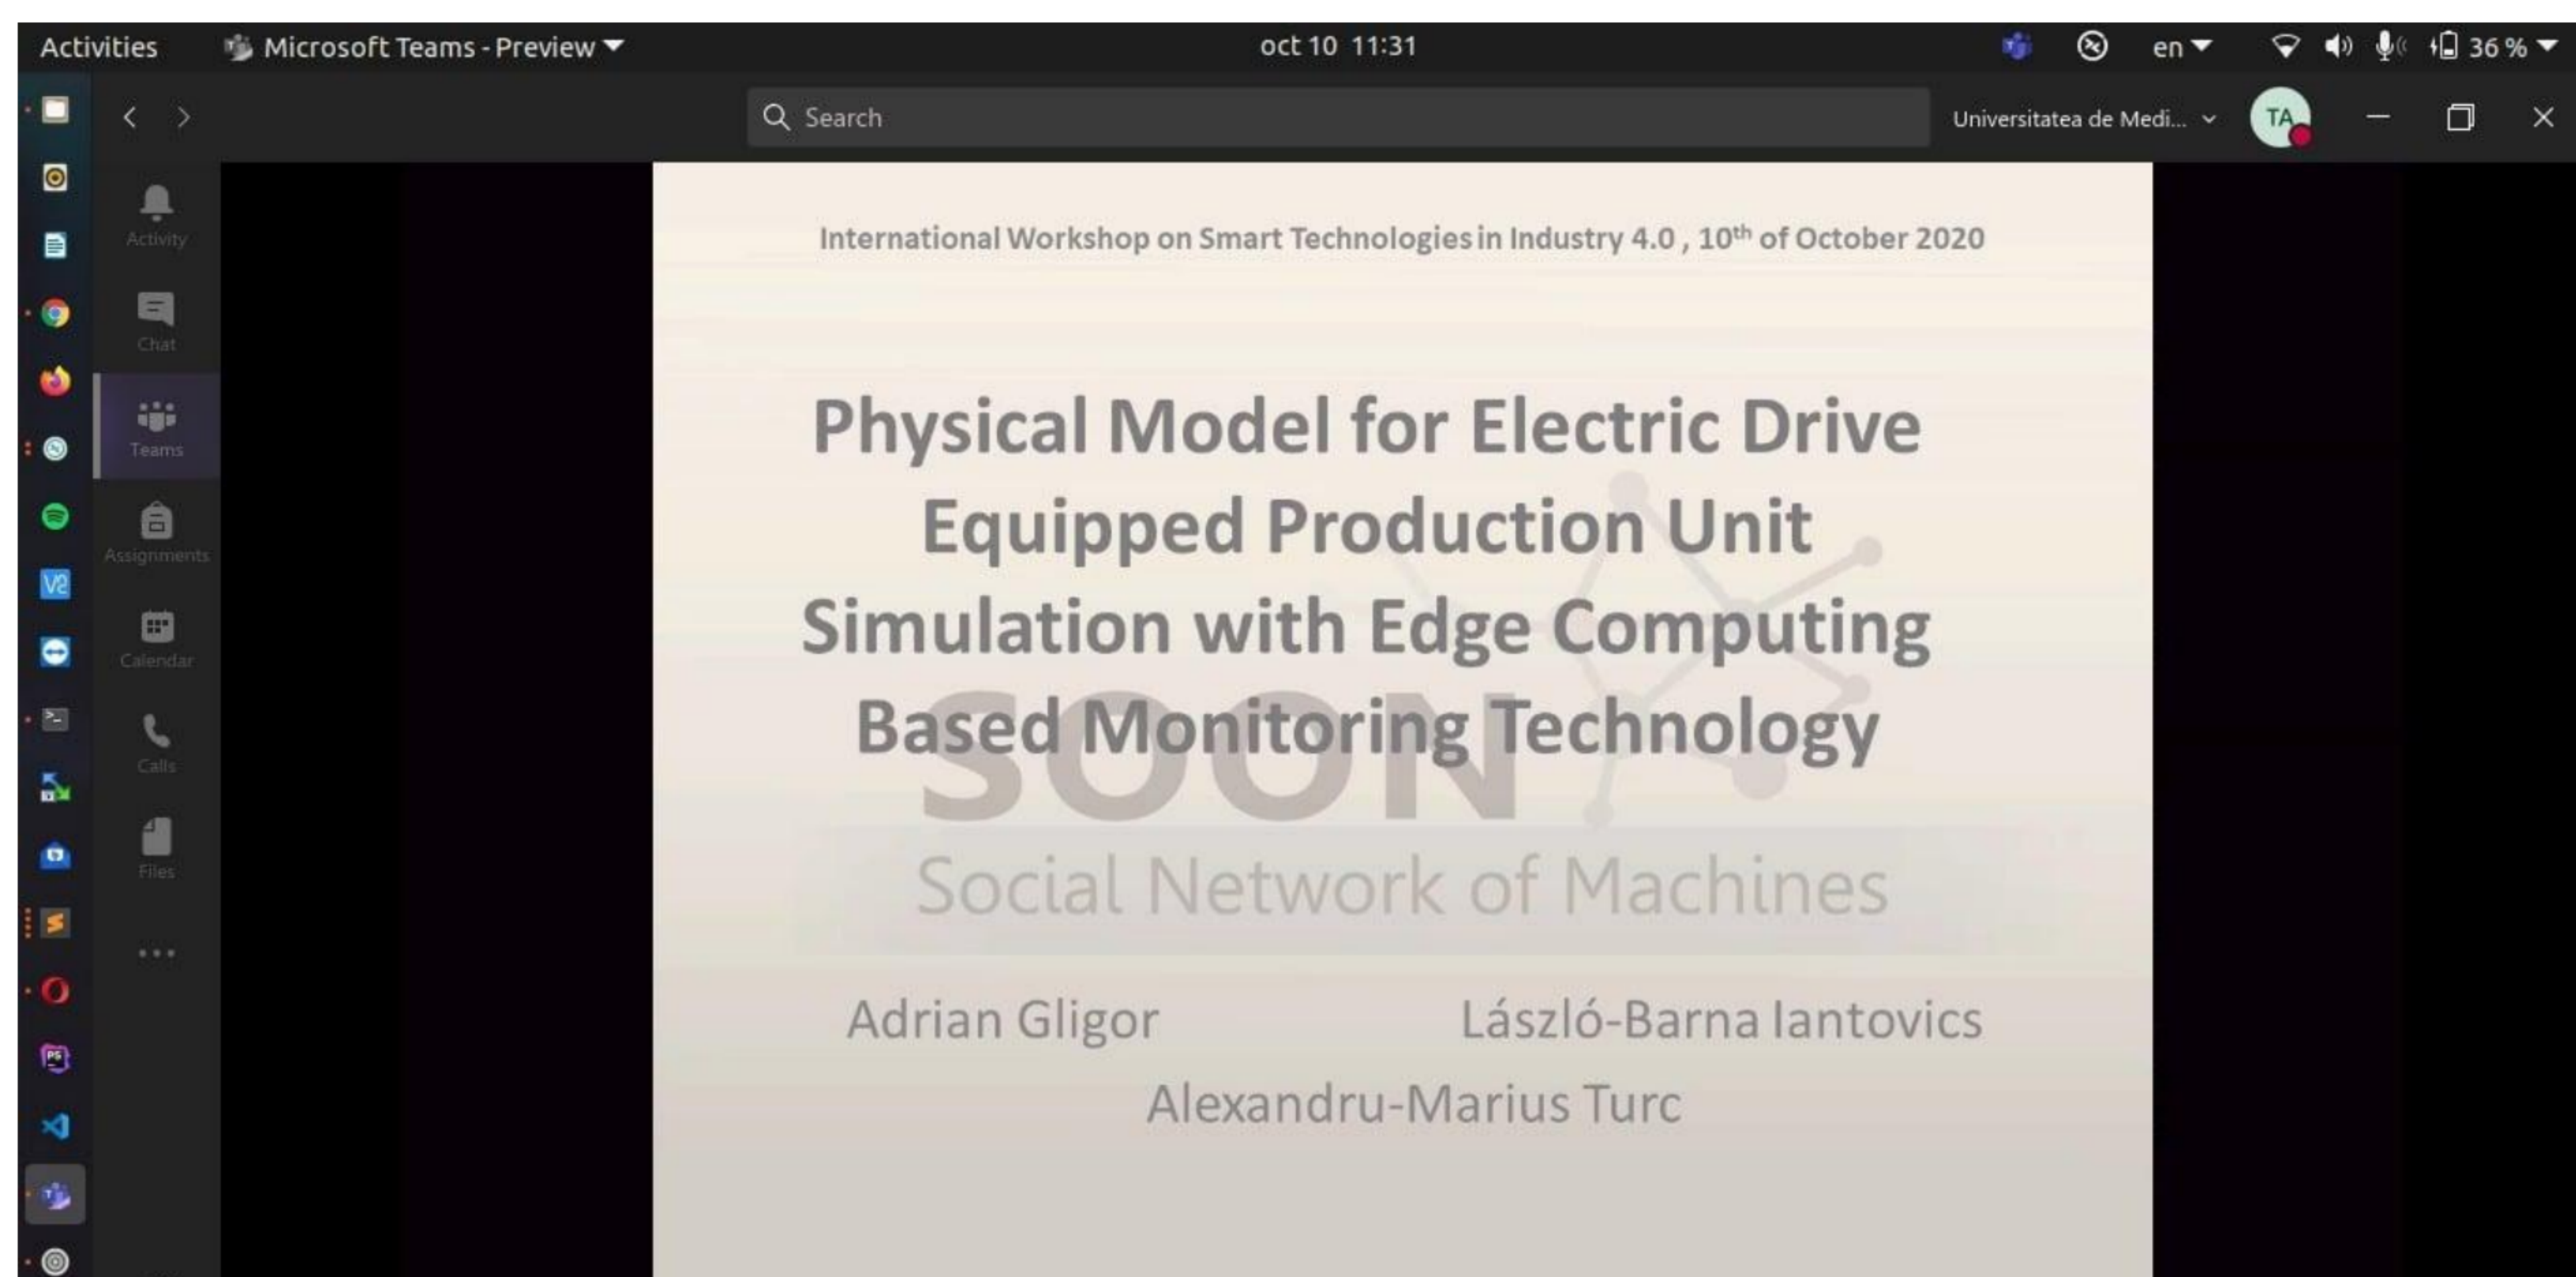


Fig. 1. Prezentarea [Gli20a] făcută de echipa UMFST în cadrul Workshopului RATIONALITY

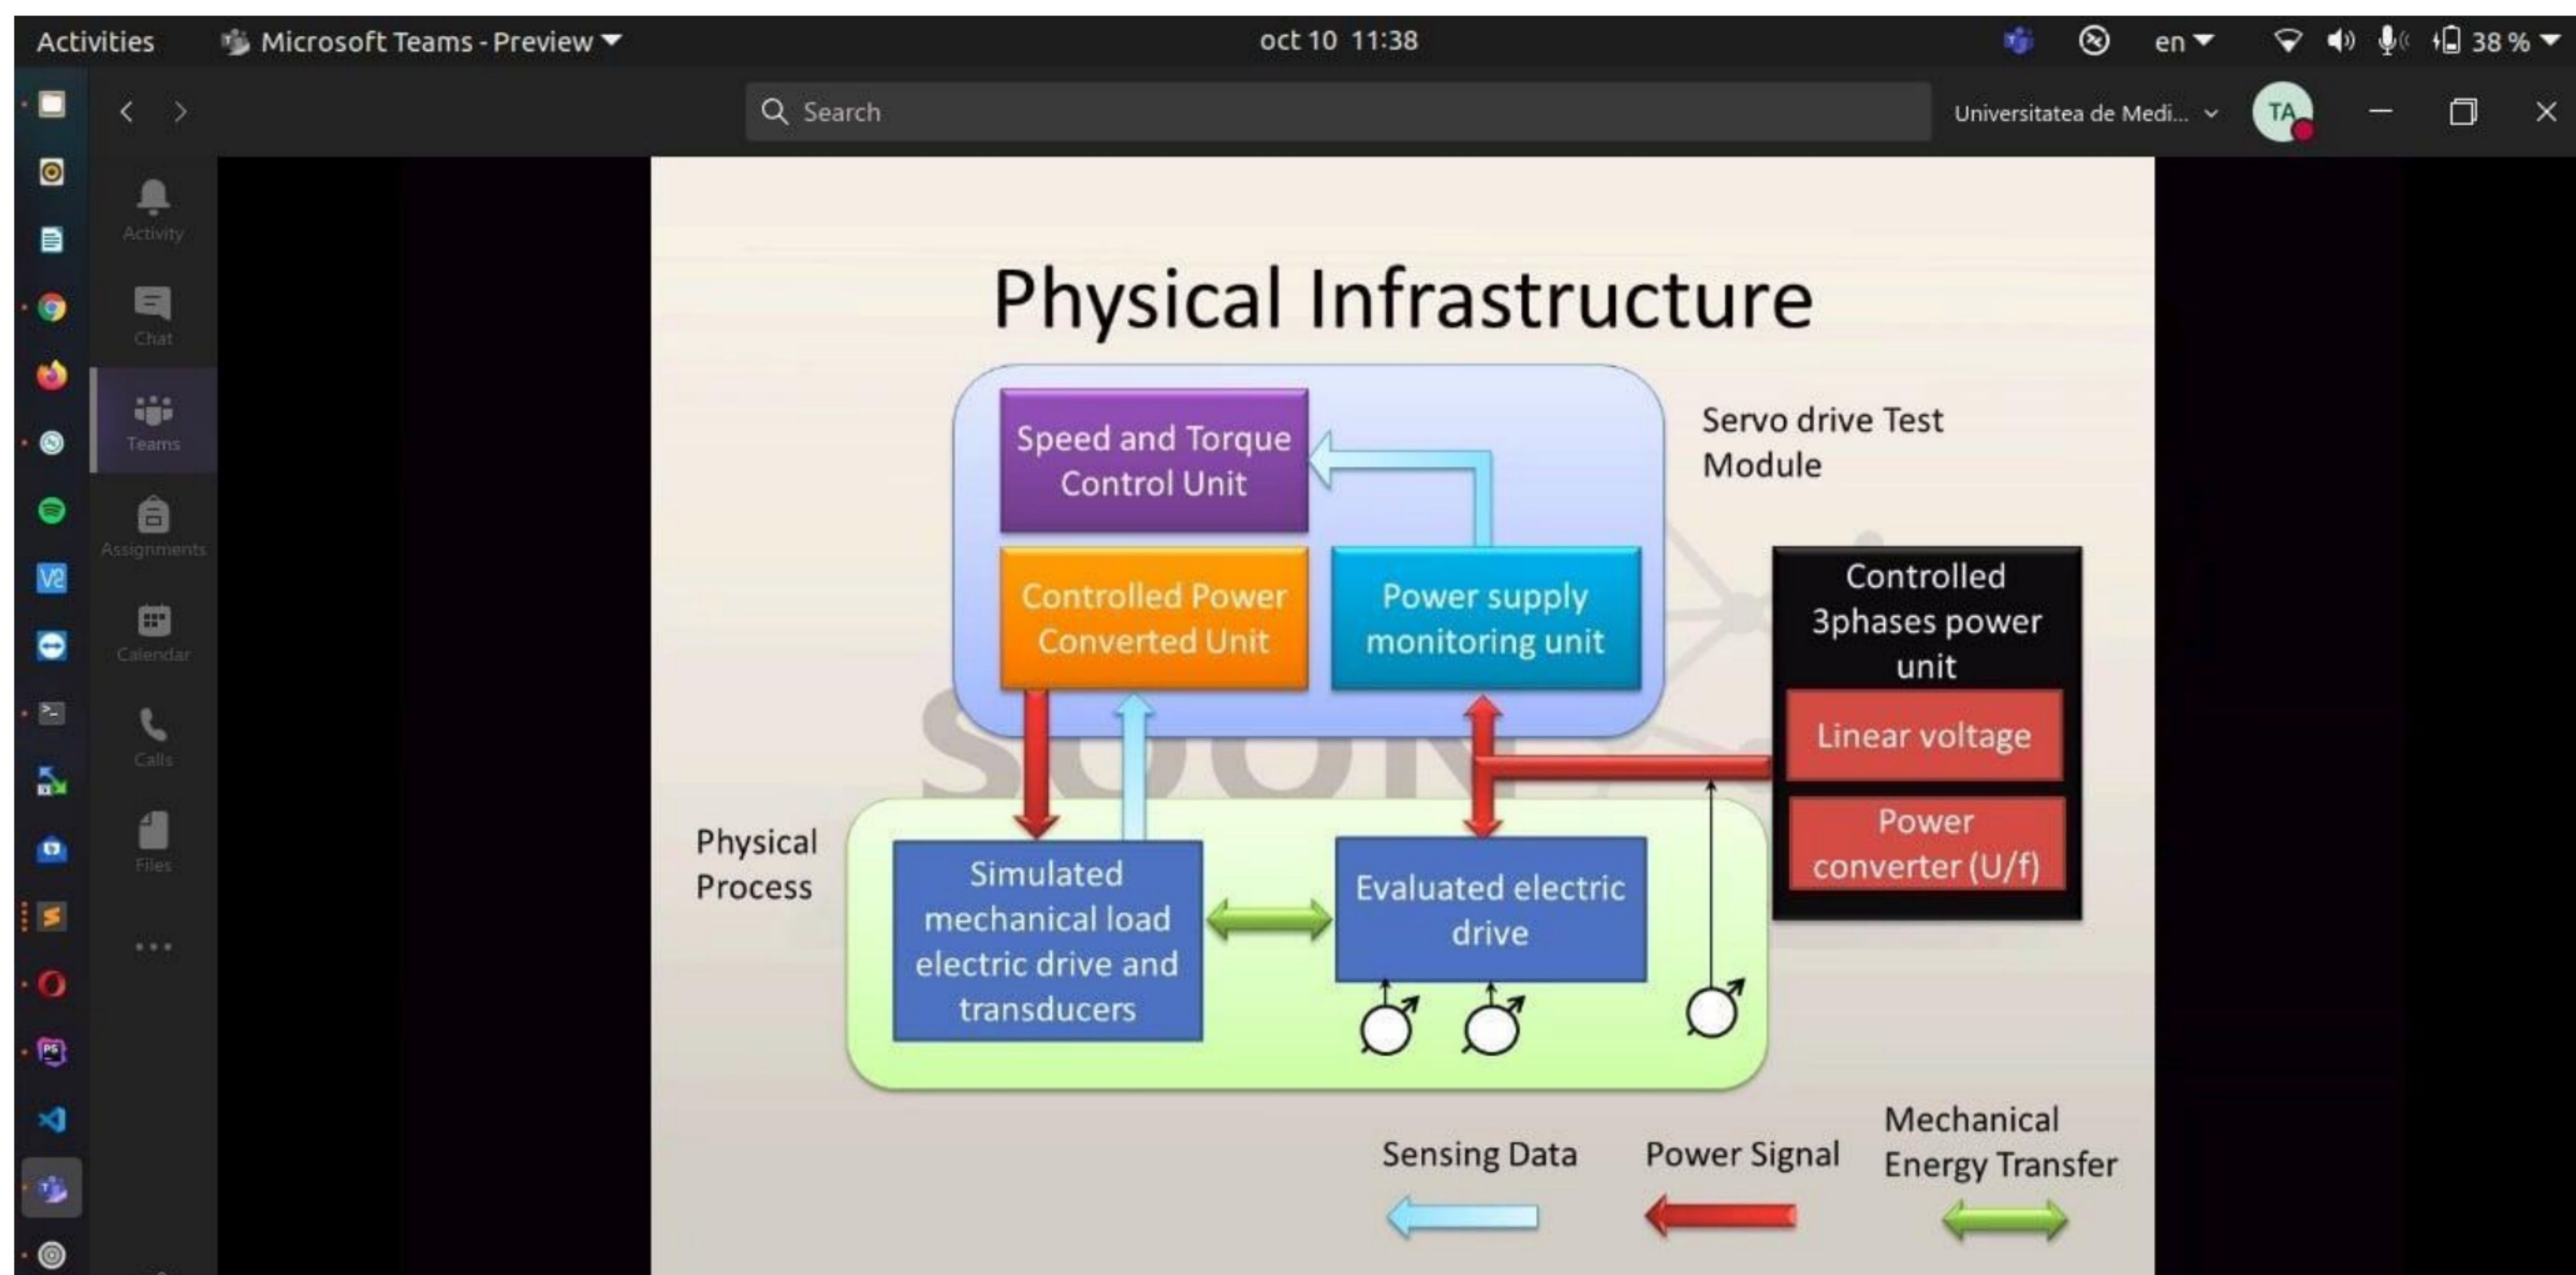


Fig. 2. Prezentarea [Gli20a] făcută de echipa UMFST în cadrul Workshopului RATIONALITY

Echipa UMFST a mai efectuat o activitate de comunicare, constând într-o prezentare făcută în cadrul Raportului de progres a proiectului SOON ce a avut loc în secțiunea a II-a, prezentând rezultatele obținute membrilor echipelor SOON, FIREMAN și celorlalți participanți.

Portalul web bilingv (limba română și engleză) al proiectului SOON a fost actualizat, prezentând informațiile relevante referitoare la proiect, specifice etapei actuale a derulării proiectului, printre care se numără obiectivele și rezultatele obținute de echipa UMFST, precum și rezumatul etapei în limba română și engleză.

2.5.2. Publicații apărute

În etapa a II-a a proiectului o serie de rezultate obținute au fost publicate într-o revistă de top, referința [Vla20] din lista de referințe bibliografice. Publicațiile specifice primei etape au fost prezentate în cadrul raportului aferent Etapei I.

2.6. Platforma pilot de testare și evaluare soluții IIoT/IoE pentru mentenanță predictivă

În Etapa I-a a fost începută, apoi continuată în Etapa a II-a, dezvoltarea unei *Platforme pilot de testare și evaluare soluții IIoT/IoE pentru mentenanță predictivă*. Pe baza bugetului aferent anului 2019 planificat pentru acest scop au fost achiziționate echipamente de procesare, comunicații și dispozitive de câmp (SBC și SoC) care au fost integrate într-o platformă pilot de testare a soluțiilor ce vor fi concepute pentru implementarea algoritmilor necesari în paradigma propusă de mentenanță predictivă, modelând sistemele de producție reale aferente mediului industrial specific partenerilor din mediul industrial. Soluția de testare constă dintr-o unitate HPC, două stații de lucru, o rețea de comunicație cu nod de comunicații de mare viteză și management, și zece sisteme SBC conectate via PoE ca sisteme de tip concentrator de date de la senzori via soluții SoC.

Standul experimental construit are rolul de model fizic a unor clase de procese industriale a căror funcționare se bazează pe acționări electrice trifazate cu turație variabilă. Standul poate fi configurat pentru rularea diferitelor scenarii necesare obținerii unor date diversificate asemănătoare sistemelor reale din industrie. Infrastructura dezvoltată permite generarea unei cantități și diversități mari de date, care vor fi considerate intrări pentru algoritmi de IA (de predicție, clasificare, machine learning etc.) care urmează a fi dezvoltați în cadrul proiectului.



Fig. 3. Stand experimental pentru achiziție de date




Fig. 4. Eșantion de date obținut de pe platforma de testare

În etapa a II-a achizițiile au cuprins suporturi de stocare pentru soluțiile SBC, diferiți senzori pentru achiziția semnalelor din procesele industriale și o stație de lucru de mare performanță.



Fig. 5. Stația de lucru achiziționată în anul 2020

3. Descrierea științifică și tehnică

3.1. Aspecte preliminare

În acest proiect propunem spre investigare eficiența unei soluții fundamentate pe o paradigmă holistică bazată pe agenți inteligenți sociali care sunt asociați mașinilor cât și operatorilor umani. Operatorii din postura de experți vor furniza cunoștințe, dar în același timp vor beneficia de rezultatele prelucrărilor și procesărilor efectuate de agenți, ce pot fi utilizate în procesele decizionale. Acest lucru presupune printre altele implementarea a diverși algoritmi de extragere de valori și caracteristici, respectiv algoritmi de învățare profundă cu scopul optimizării funcționării proceselor industriale analizate. Mulți algoritmi vor fi utilizați pentru soluționarea problemelor asociate mentenanței predictive. Aceștia trebuie să utilizeze cantități mari de date eterogene furnizate de o diversitate mare de echipamente și dispozitive (senzori, sisteme de control automat, roboți), dar care vor trebui să concure la soluționarea în timp real a sarcinilor complexe privind mentenanța predictivă. Alături de măsurătorile în timp real, sursele de date utilizate vor mai consta în înregistrări istorice, disponibile sub forma unor serii de timp, unele având ca sursă sistemele ERP.

Soluția dezvoltată se va baza pe specificațiile provenite de la toate companiile industriale implicate în proiect cu activitate industrială din domenii și profil diferit. Viziunea generală pe care se bazează arhitectura propusă, este prezentată în Fig. 6. Principala cerință a proiectării constând în asigurarea scalabilității, astfel încât să permită înglobarea în mod dinamic a unor entități precum mașini fizice și procese, dispozitive, senzori și infrastructură TIC constând din sisteme inteligente de procesare în cloud, concentratoare de date și software de prelucrare și analiză.

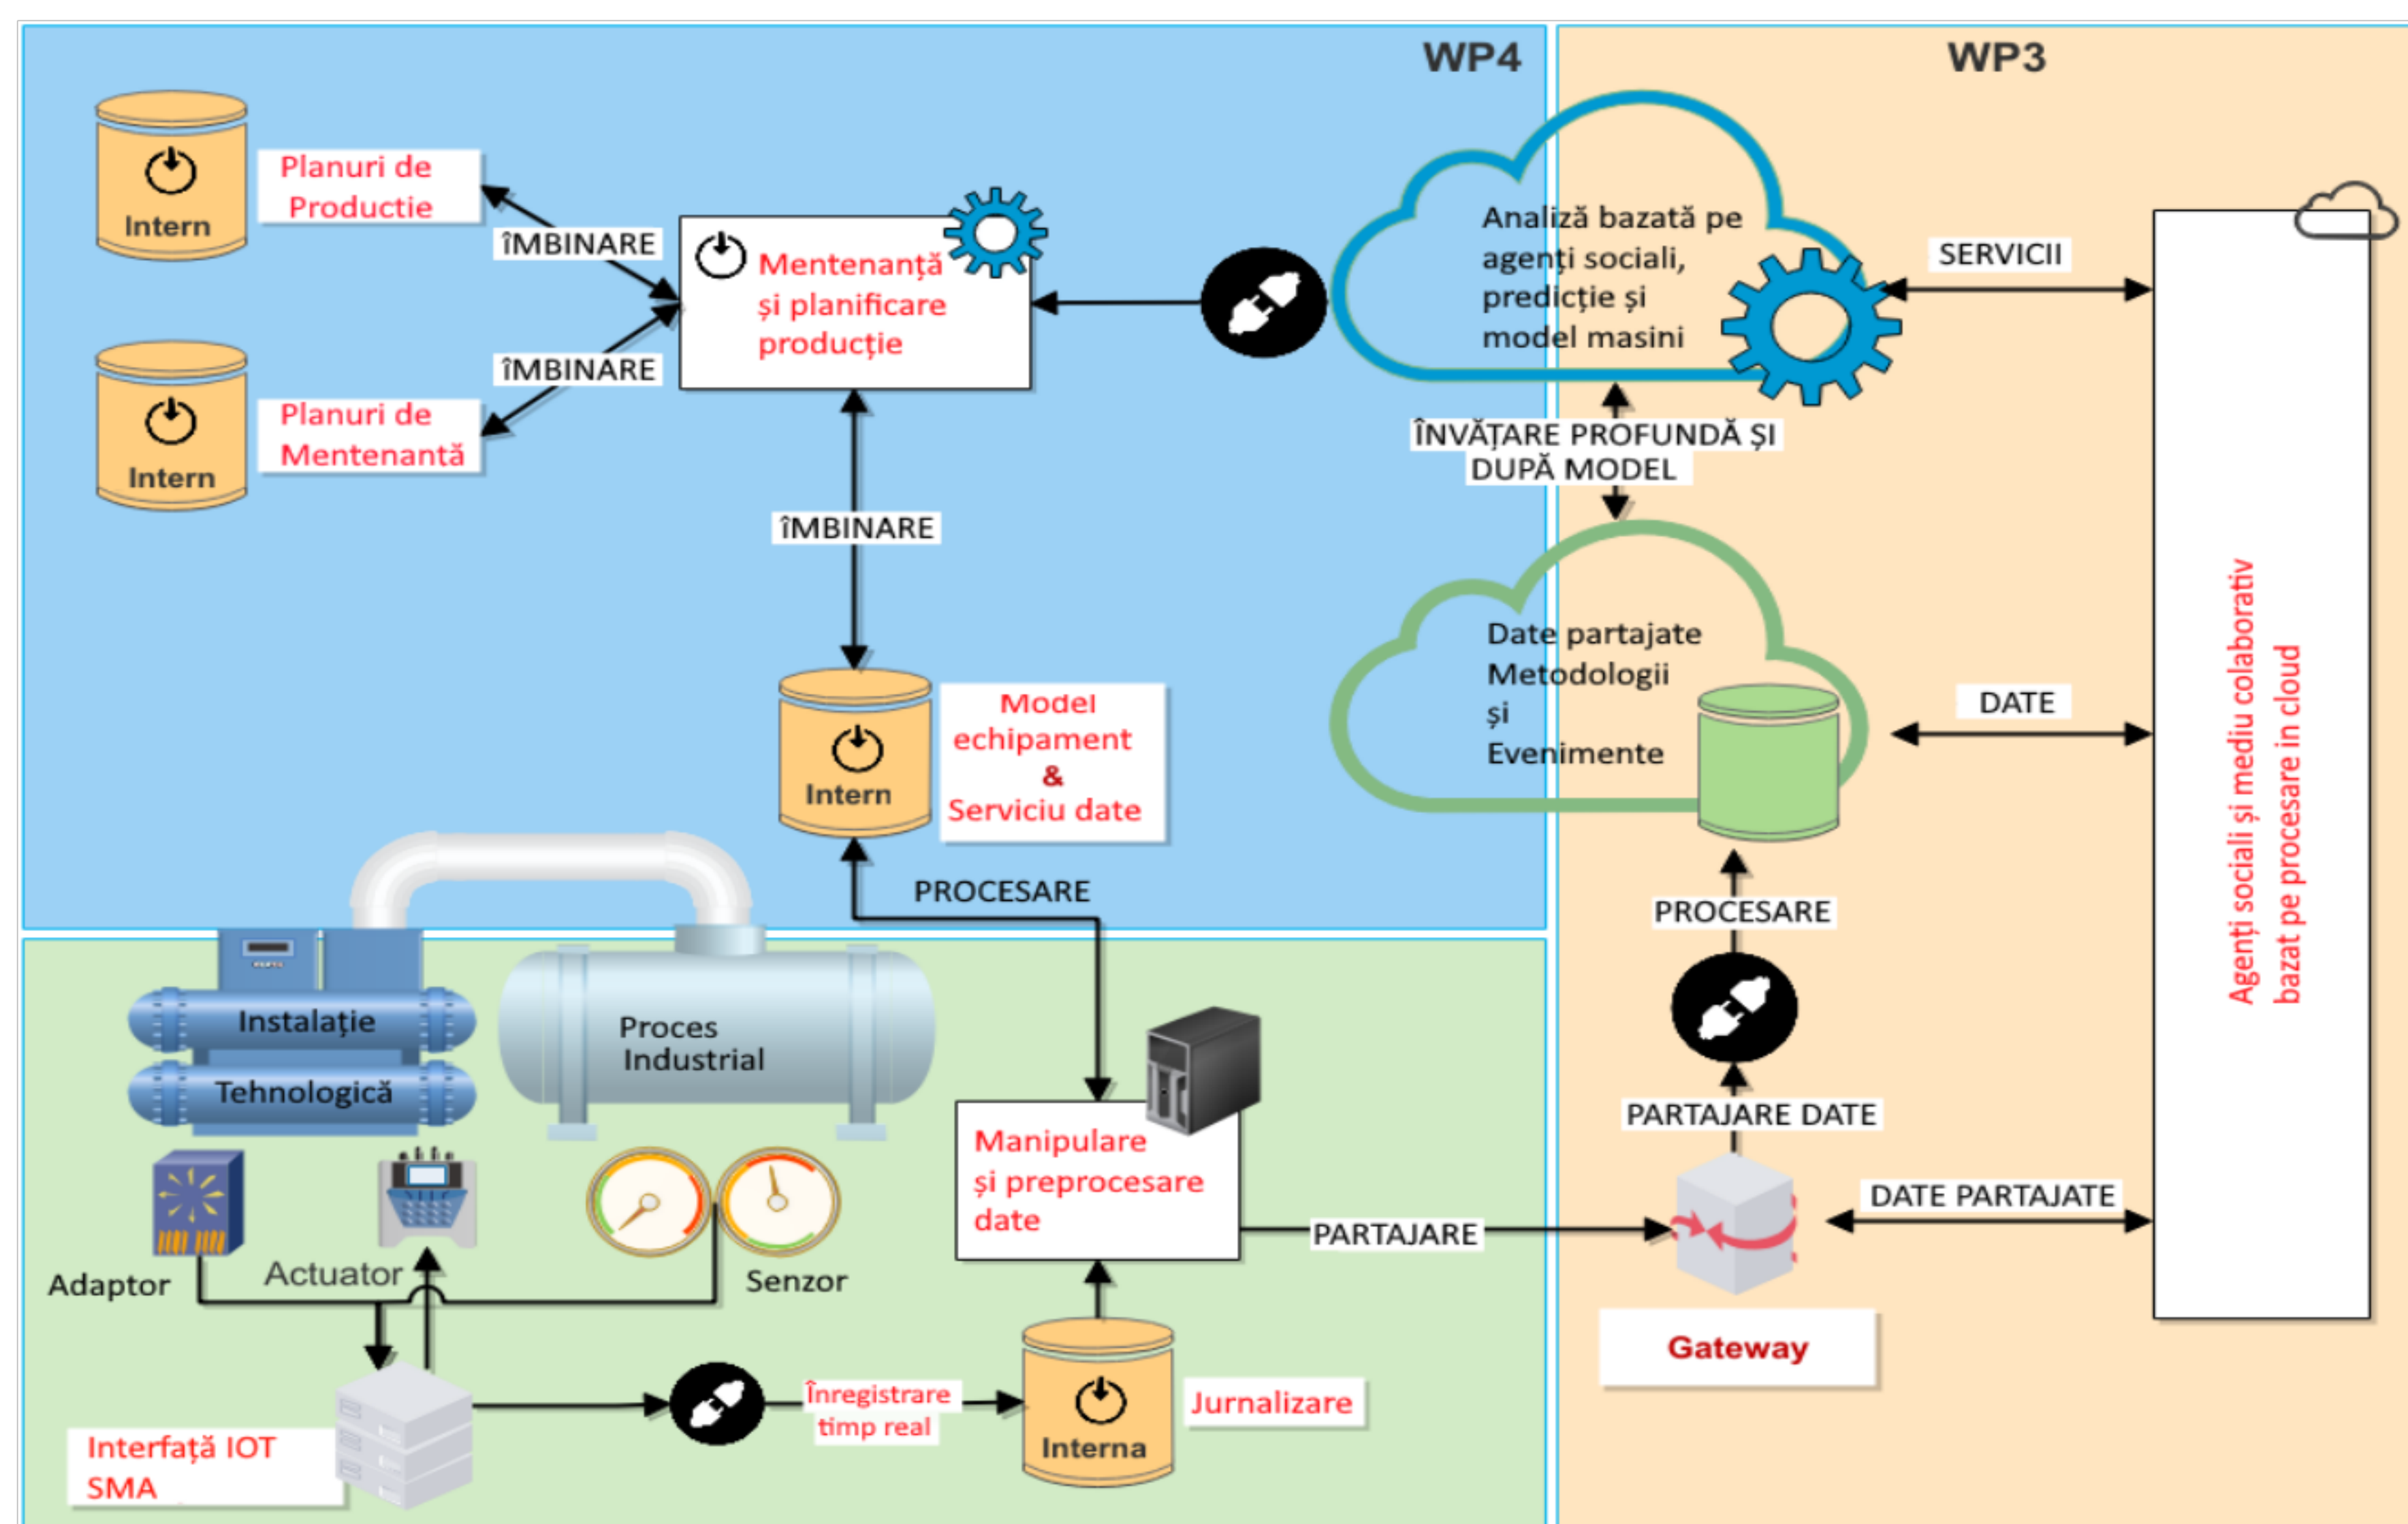


Fig. 6. Soluția SOON propusă pentru mentenanța predictivă.

3.2. Specificații industriale model de integrare date

Acest capitol descrie pe scurt modelele de date utilizate pentru stocarea tuturor datelor provenite de la diverse surse pentru fiecare dintre scenariile care au fost definite în colaborare cu partenerii industriali (Tornos, MAT-obaly și ArcelorMittal).

3.2.1. Surse de date ale partenerilor industriali

Sursa principală de date considerată cuprinde: date istorice din ERP, înregistrări privind operarea utilajelor și mașinilor unelte, date din loggere, date în timp real de la senzori și dispozitive de înregistrare.

3.2.2. Identificarea surselor de date ale fiecărui scenariu

Raportul științific și tehnic în subcapitolul cu același nume “Identificarea surselor de date ale fiecărui scenariu” prezintă în detaliu fiecare caz de utilizare (use case) din scenariile identificate. Pentru fiecare caz de utilizare, sunt identificate sursele de date principale.

3.2.3. Descrierea modelului de stocare a datelor

În continuare sunt prezentate modelele de stocare pentru fiecare sursă de date. Datele se prevăd a fi stocate apelând la tehnologii compatibile cu soluțiile disponibile, în prezent acceptare și utilizate la scară mare.

Modelul de date propus

Pornind de la datele disponibile și scenariile analizate s-a proiectat un model de date specific, necesar pentru reprezentarea unificată a datelor în soluția SOON.

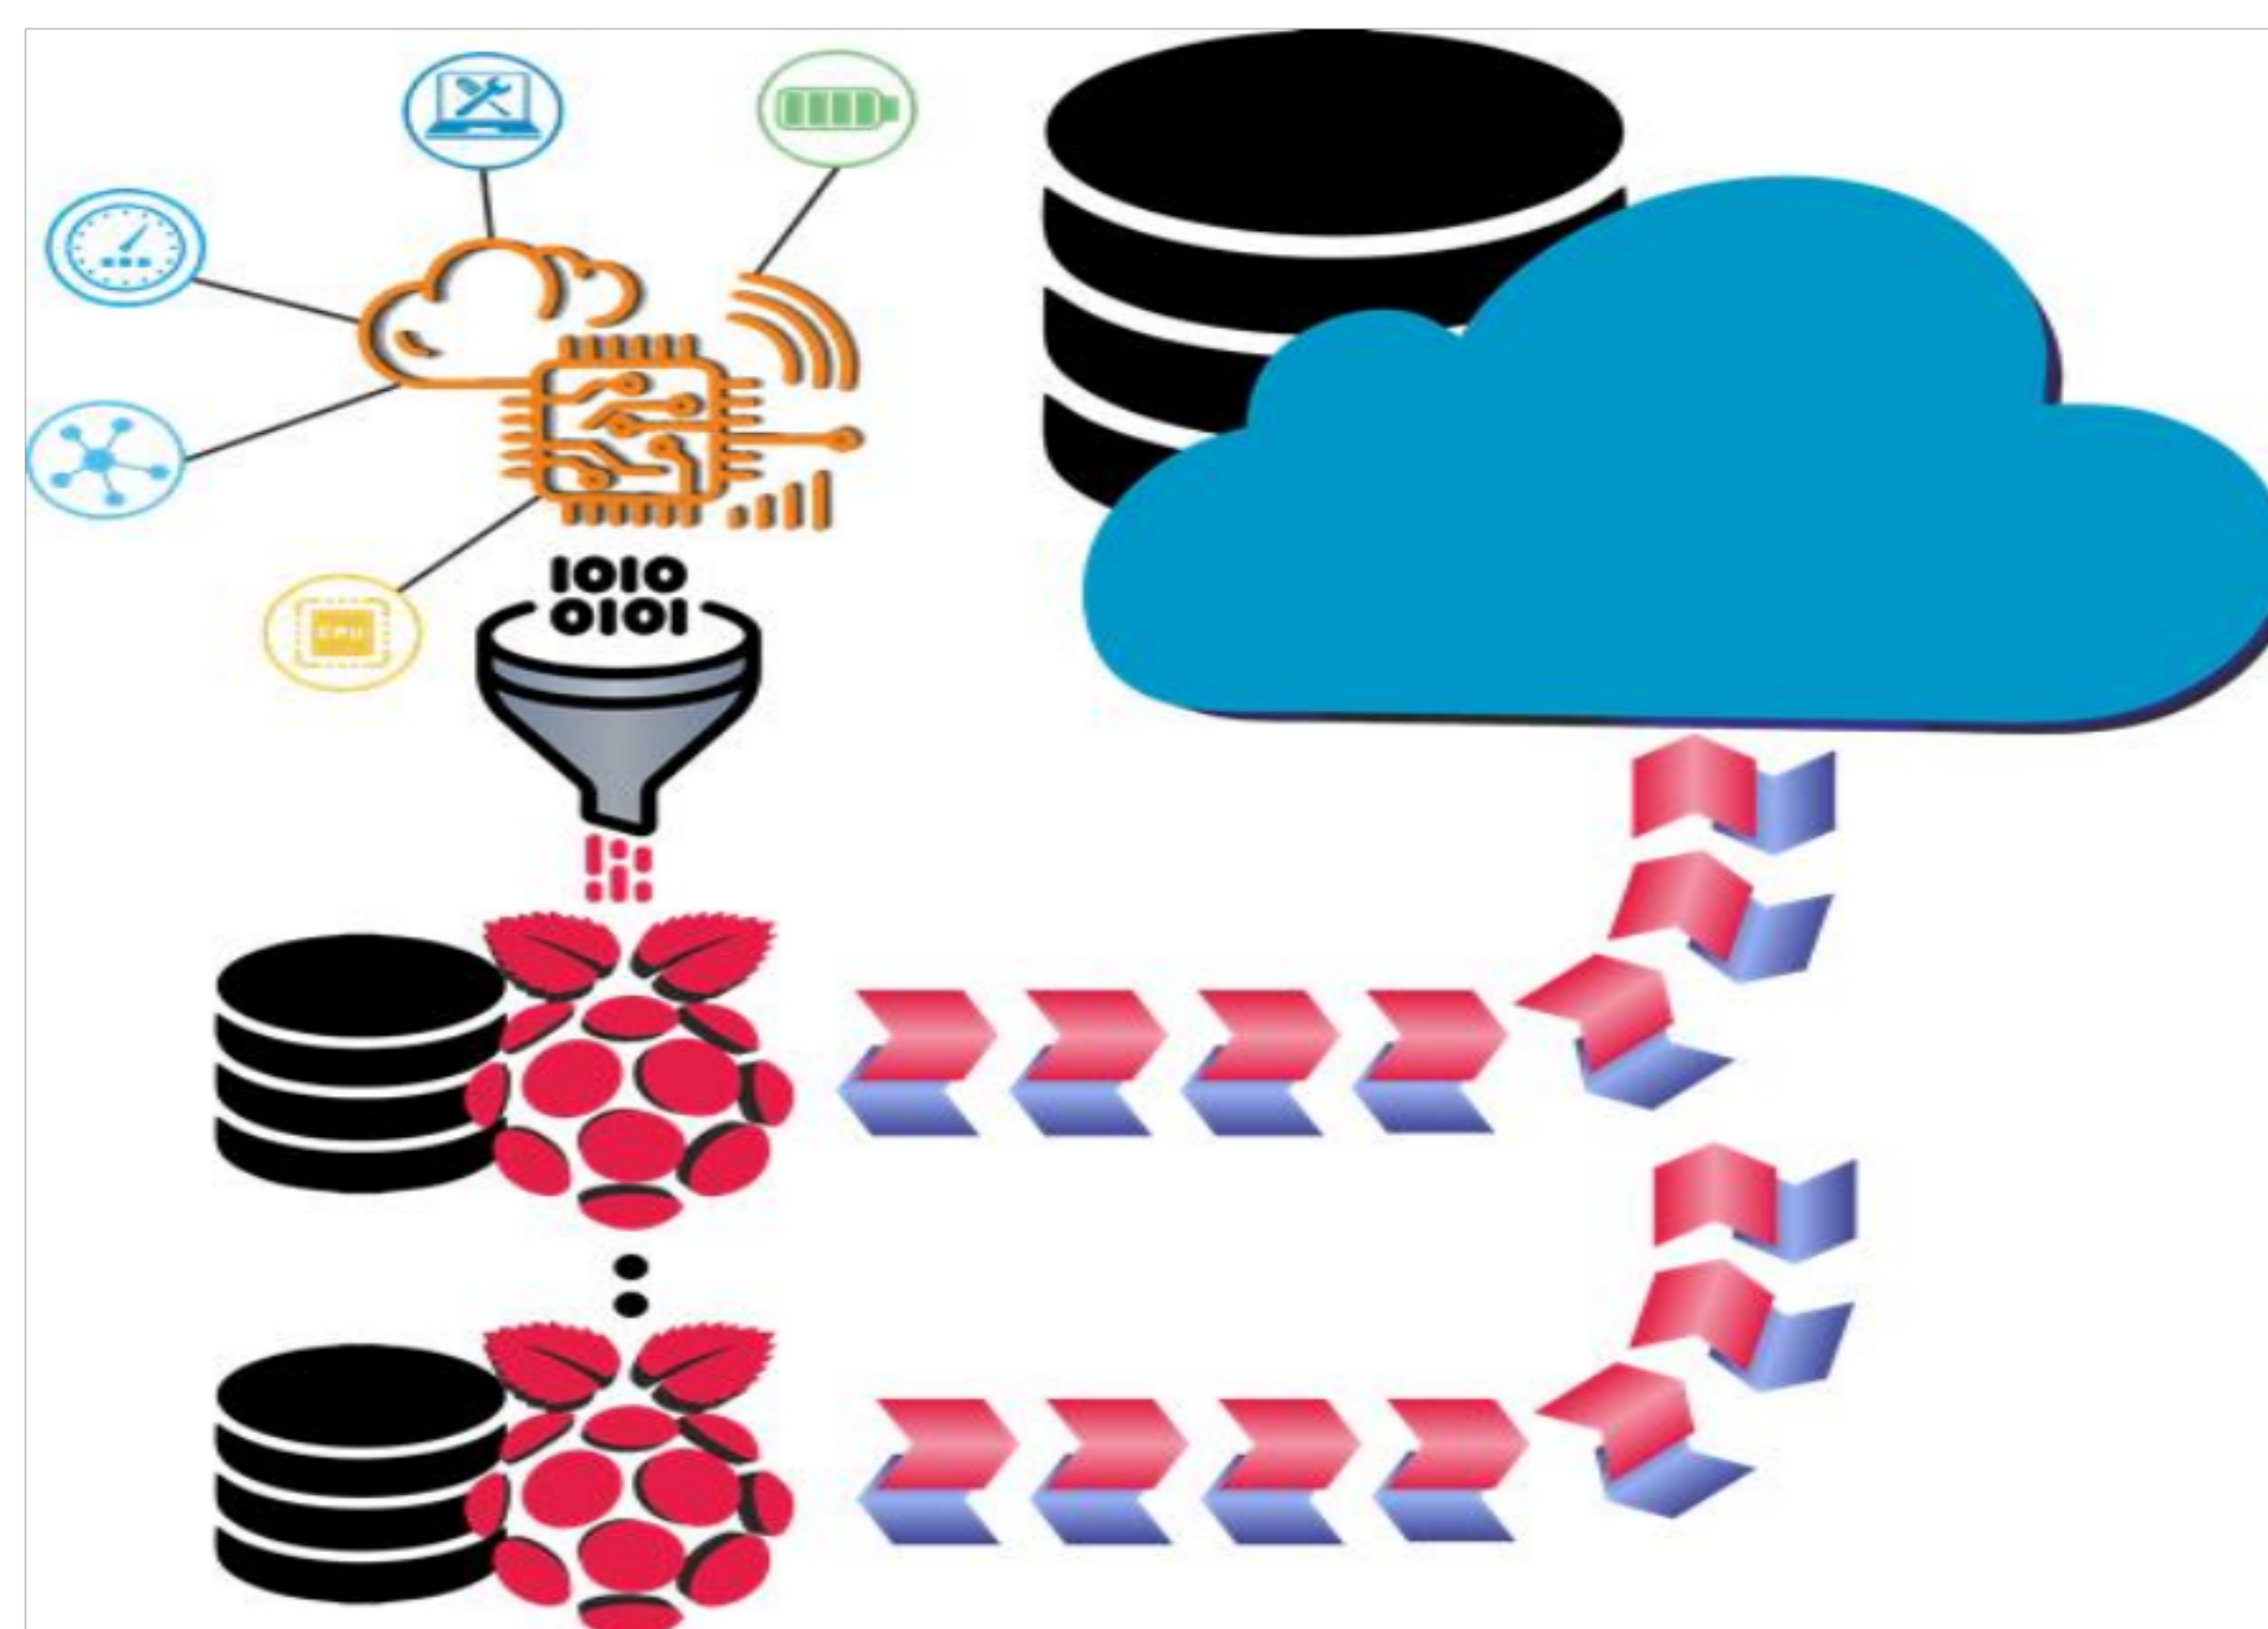








Fig. 7. Privire de ansamblu modelul de stocare

În modelul propus, datele achiziționate de la senzori  sunt transmise prin intermediul soluțiilor dedicate de achiziție implementate cu SoC  la Agenți ce rulează pe module SBC . Acești agenți stochează temporar datele primite de la senzori în baze de date locale (edge level database) , iar după aceasta, datele ajung în cloud , unde sunt stocate într-o bază de date distribuită .

3.3. Sinteză scenarii de mentenanță predictivă

RST - Anexa 7, conține o descriere detaliată a acestui subcapitol, prezentând totodată un studiu bibliografic (a se vedea de ex. [Car19, Zon20, Yan18]) efectuat referitor la mentenanța predictivă.

Scopul acestui subcapitol este de a formaliza scenariile de mentenanță predictivă care vor fi abordate în cadrul proiectului SOON. Scenariile prezentate în acest document nu se limitează la predicția defectărilor, ci cuprinde și acțiunile pe care agenții sociali (operatori sau mașini) trebuie să le efectueze după apariția unui incident sau în cazul predicției unui defect.

În cele ce urmează, prezentăm rezumatele scenariilor PdM ale proiectului SOON.

Scenariul 1: Mentenanța inteligentă a rolor laminorului de sârmă

Acest scenariu se referă la mentenanța liniei de fabricație a unui sortiment de sârmă, care reprezintă materia primă utilizată la realizarea unor produse care necesită standarde de calitate ridicată precum ar fi anvelopele, arcurile, piesele pentru realizarea îmbinărilor prin filetare, etc.

Calitatea produsului finit este determinată de o serie de subansamblele utilizate în procesul de fabricație, în cazul scenariului de față, de interes fiind rolele cajelor de laminare. Problema care trebuie rezolvată în acest caz constă în determinarea setului de role optim

(din punct de vedere dimensional, al materialului, poziționare, durată de viață) în condițiile disponibilității unui număr mare de role, în cazul de față câteva mii, și care își modifică cotele de interes după un timp de utilizare, devenind utile pentru alte ipoteze de utilizare decât cele prevăzute la intrarea lor în sistem.

Rezolvarea acestei probleme în mod tradițional nu este practică, din acest motiv doar o soluție informatică de suport a deciziilor sau chiar de operare autonomă privind alegerea și înlocuirea rolor poate furniza un rezultat adecvat, având în vedere numărul mare de variabile de intrare ale problemei, incluzând aici aspectele dimensionale, istoric de utilizare, evidența uzurii, particularități calitative, operațiile de recondiționare, stocurile disponibile, aspecte legate de mișcarea și stocarea rolor, etc.

Trei abordări diferite se propun pentru acest scenariu.

1) Problema poate fi încadrată ca o problemă de satisfacere a constrângerilor și rezolvată ca atare.

2) A doua abordare se va baza pe un sistem multi-agent cooperativ care urmează o serie de protocoalele de licitație.

3) A treia abordare va urma metode de învățare prin întărire.

Scenariul 2: Predicția uzurii uneltelor

Acesta este un scenariu PdM care vizează prezicerea eficacității actuale a anumitor unelte de prelucrare. Degradarea accentuată a unei unelte poate determina o productivitate redusă. Predicția se poate baza pe operații predefinite, efectuate la intervale predefinite sau conform criteriilor prescrise și este menită să reducă probabilitatea întreruperii necontrolate a producției. Prin urmare, întreținerea preventivă va ține seama de utilizarea efectivă sau de constrângerile la utilizarea acesteia. Această întreținere se bazează pe predicțiile extrapolate ale analizei și evaluării parametrilor semnificativi referitori la degradarea uneltelor. Prin prezicerea uzurii unei unelte, este posibilă optimizarea procesului de înlocuire, determinând astfel momentul adecvat al acestei operații.

Propunerea SOON este de a utiliza algoritmi de învățare automată pentru a prognoza durata de viață utilă rămasă a uneltelor (RUL).

Scenariul 3 – Predicția automată a comenzilor de lucru

Într-un atelier de producție, piesele sunt procesate de diferite tipuri de mașini de-a lungul liniei de producție. Pentru finalizarea unei părți a unei piese de regulă sunt necesare mai mulți pași de parcurs. Fiecare dintre acești pași sunt realizați de o mașină configurată pentru a efectua o acțiune specifică dorită. În plus, mașinile din linia de producție sunt eterogene și au proprietăți și caracteristici diferite, în funcție de tipul piesei pe care o produc sau de procesul în care sunt implicate. Într-un atelier, toate aceste acțiuni sunt efectuate pe

diferite mașini în paralel și transferate de la un dispozitiv la altul. Astfel, cu cât este mai mare numărul de mașini prezente în atelier, cu atât există mai multe variante diferite pentru producerea pieselor dorite. Datorită varietății căilor de urmat, uzual este dificil de prezis dacă o comandă poate fi îndeplinită în timpul dorit. Mai mult, linia de producție poate fi complet întreruptă în cazul unei defecțiuni (previzionate) a uneia sau mai multor mașini din fluxul tehnologic.

Obiectivul în cadrul proiectului este de a identifica metodele de învățare prin întărire capabile să conducă la optimizarea unui sistem complex de producție dintr-un atelier. Folosind aceste metode de optimizare, urmărim să identificăm noi strategii de coordonare și planificare a producției.

Scenariul 4 – Suport inteligent al deciziilor de întreținere

Serviciul post-vânzare este un departament esențial pentru furnizorii de mașini unelte și pentru ciclul de viață al acestora. Un timp de reparație mai scurt se cuantifică într-un timp de repunere în funcțiune mai scurt. În acest sens, cel mai mare impact asupra producției este cauzat de perioadele de nefuncționare neplanificate.

Acest scenariu vizează îmbunătățirea serviciului departamentului post-vânzare atunci când apare o defecțiune. Pentru a reduce timpul de nefuncționare al unei mașini, este important să putem identifica cât mai timpuriu apariția defecțiunilor sau chiar realizarea unor predicții privind apariția acestora.

Propunem realizarea unei baze de cunoștințe cu istoricul tuturor defectărilor care au avut loc. Ideea principală este de a conecta informațiile cu incidentele din trecut și prezent într-o interfață inteligentă pentru utilizatorul final.

Scenariul 5 – Detectarea automată a defecțiunilor senzorilor

Producția industrială modernă este în mare parte complet automatizată, bazându-se pe calitatea datelor colectate necesare pentru a controla procesele de producție. Procesarea automată utilizează datele furnizate de diferiții senzori instalați de-a lungul fluxurilor de producție. Prin urmare, calitatea acestor date este esențială pentru a atinge standarde operaționale înalte. Există medii industriale în care senzorii nu pot opera în condiții adecvate datorită unor factori precum: murdăria, vibrațiile, temperaturi ridicate, etc. Instalarea redundantă de senzori nu este fezabilă uneori.

Obiectivul principal al laminării este de a obține tablă la o anumită grosime. Condițiile de laminare determină variația grosimii de-a lungul fluxului de prelucrare. Asigurarea condițiilor adecvate permit controlul grosimii cerute de client. Grosimea benzii evoluează de-a lungul fluxului tehnologic și este monitorizată de mai mulți senzori fără redundanță, ceea

ce face foarte dificilă verificarea calității măsurătorilor. Datele furnizate de senzori ar putea fi afectate de diferite zgomote sau perturbații.

Validarea măsurătorilor grosimii de-a lungul procesului de laminare se va baza pe coerența dintre valorile reale și estimarea acestora, prin urmare modelarea măsurătorilor furnizate de senzori este esențială. Trebuie să obținem mai multe modele pentru a estima valoarea grosimii într-un anumit punct al procesului. Abordarea în cadrul proiectului presupune construirea unor modele predictive capabile să estimeze valoarea măsurată de un senzor de grosime la o poziție specifică în procesul de producție (de exemplu, ieșirea stației de finisare), folosind ca intrare măsurătorile senzorilor de același tip situați în alte etape de-a lungul liniei de prelucrare și combinând alți parametri de proces și informații de la agenții umani.

În cadrul proiectului au fost propuși și dezvoltați doi algoritmi de predicție: primul, care se bazează pe datele măsurate la ieșirea instalației de degroșare și alte variabile de producție (temperatură, compoziția chimică a oțelului etc.), respectiv al doilea ce utilizează ca date de intrare măsurătorile obținute de la mașina de înfășurare împreună cu alte variabile de producție.

Scenariul 6 – Utilizarea datelor de consum de energie electrică pentru predicția întreruperilor

În prezent monitorizarea consumurilor de energie este frecvent întâlnită, în principal datorită necesității menținerii controlului atent asupra costurilor și a fost facilitat de dezvoltarea sistemelor inteligente de măsurare. În marea majoritate a situațiilor datele sunt examinate doar vizual de către un manager de operațiuni într-un mod ad-hoc. Situația dorită ar fi ca să existe un mod automat de monitorizare și alertare legat de consumul individual al echipamentelor și de a evalua în timp real modificările bruște ale caracteristicilor de consum.

Odată cu monitorizarea consumurilor energetice, sunt înregistrate și date despre defecțiuni și întreruperi. Prin descoperirea dependențelor dintre consumul de energie electrică și întreruperi, problemele din fluxul tehnologic datorat acționărilor electrice pot fi identificate, și posibil prezise.

Scenariul 7 – Detectarea defecțiunilor acționărilor electrice

În prezent, există cu precădere un control empiric asupra stării acționărilor electrice, care sunt inspectate de operatorii instalațiilor, verificări care sunt în esență doar un mecanism de control pasiv. Defectarea unui motor electric poate implica întreruperi grave ale producției. Prin urmare, ar fi extrem de important să avem modalități de monitorizare a fiecărei acționări electrice și de a prezice diverse probleme care pot apărea, în vederea

reparării sau înlocuirii unor părți ale sistemului de acționare, sau în ceea ce privește planificarea înlocuirii complete a întregului sistem de acționare.

Obiectivul principal este de a minimiza perioadele de reparație/întreținere. În cazul ideal, perioadele de întreținere se potrivesc cu întreținerea altor echipamente din fabrică sau se încadrează în perioada în care linia de producție este configurată pentru diferite tipuri de producție.

Abordarea pentru detectarea defecțiunilor unei acționări electrice se va baza pe metode analitice de căutare a anomaliilor în datele colectate în timpul funcționării acestora. Fiecare acționare importantă dintr-o linie de producție ar trebui să fie echipată cu senzori care monitorizează datele operaționale și de mediu. Aceste date sunt centralizate și, în plus, sunt transferate agenților care rulează modele de procesare a acestora și de detectare a defecțiunilor. Fiecare agent estimează periodic probabilitatea de avarie și, dacă avarierea acționării electrice devine iminentă în scurt timp, îi avertizează pe inginerii din fabrică să planifice mentenanța acționării electrice. Modelul analitic trebuie să poată detecta indicațiile fals-pozitive, deoarece chiar și senzorii se pot defecta în timpul funcționării. Pentru a identifica senzorii defecti, o soluție este ca mai mulți senzori de temperatură să fie instalați pe o acționare pentru a furniza valorile de interes.

Scenariul 8 – Modelarea și simularea configurației atelierelor

Luarea deciziilor cu privire la amplasarea utilajelor într-un atelier poate ajuta la optimizarea proceselor de fabricație. Pot fi utilizate diferite tehnici de IA, printre care și instrumente de simulare virtuală în astfel de scopuri.

Simularea bazată pe modelarea configurației unui atelier trebuie să ofere următoarele funcționalități:

- modelare virtuală la nivel de atelier (scenarii actuale și potențiale);
- simularea unei setări reale sau realizarea unei reconfigurări la nivelul atelierului;
- simulări de tip „ce ar fi” referitoare la reconfigurarea resursei (mașini, materiale, echipamente, resurse umane) în atelier;
- generarea de date pentru mentenanță predictivă bazată pe agenți;
- efectuarea de copii digitale (Digital Twin): modele digitale în evoluție bazate pe istoricul operațiunilor pentru analiza și optimizarea performanței proceselor.

Un caz de utilizare se referă la modelarea configurației unui atelier pentru amplasarea optimă a utilajelor, cu scopul de a obține cea mai mare eficiență posibilă a proceselor de fabricație. Diferite loturi de comenzi vor fi folosite pentru a testa diverse amplasări de mașini la nivelul unui atelier, sincronizarea activității de fabricație și optimizarea logistică a fluxului de producție. Generarea optimă a planificării va presupune utilizarea apriorică a unor instrumente de simulare. Diferite opțiuni de amplasare a mașinilor vor fi testate fie în modul on-line, fie off-line. Pe lângă mașini și operatori, această simulare va ține seama și de alte

componente din ciclul de producție, cum ar fi transportul, stocurile tampon sau mijloacele de transport interne.

Modelele digitale ale unui atelier pot oferi o legătură aproape în timp real între lumea fizică și cea digitală. Datele operaționale colectate pot fi utilizate pentru a înțelege și elimina inadecvările operaționale frecvente. Alocarea optimă a operațiilor pe mașini poate fi realizată printr-un astfel de model. Tehnicile de învățare automată pot fi utilizate pentru a învăța setările curente de operare ale mașinilor și pentru a prezice perioada de finalizare a comenzii.

3.4. Specificații și arhitectură sistem social multiagent

Specificațiile de sistem și arhitectura propusă a fost elaborată în cadrul Documentului 5.1. livrabil la nivel de proiect intitulat "System and Architecture Specification". Arhitectura propusă este concepută în contextul a două arhitecturi generice de referință: RAMI 4.0 [Deu16] și IIRA [Ind17], arhitecturi des întâlnite în cadrul abordărilor I4.0. Detalii sintetice referitoare la aceste abordări pot fi consultate de exemplu în lucrările: [Far20] și [Tru19].

3.4.1. Aspecte preliminare

Un sistem de întreținere predictivă standardizat pentru ecosistemele de tip Industry 4.0 reprezintă o abordare nouă, complementară sistemelor automatizate de producție (AP), ce integrează la nivel sistemic diversele entități cum ar fi dispozitive, instrumente, procese, agenți, senzori și servicii, care împreună concurează la atingerea obiectivelor sistemului de producție considerat. Pentru a gestiona complexitatea și diversitatea unor astfel de sisteme, o arhitectură dedicată acestora reprezintă instrumentul cel mai potrivit de descriere.

Arhitectura SOON proiectată se remarcă prin faptul că înglobează conceptele propuse în cadrul proiectului, pornind de la cerințele industriale identificate în cadrul activităților întreprinse în PL2 și sintetizate în livrabilul D2.1 la nivel de proiect în Etapa I. Chiar dacă arhitectura propusă se adresează în mod direct contextului întâlnit în cadrul proiectului, acesta prin gradul său de generalitate poate fi adoptat cu ușurință în orice sistem industrial ce satisface principiile conceptuale ale Industriei 4.0 și Industriei inteligente.

În RST sunt descrise următoarele subsubcapitole introductive, ale subcapitolului curent:

- *Arhitectura SOON în contextul arhitecturilor de referință;*
- *Cerințe specifice arhitecturilor IT pentru Industria 4.0;*
- *Provocări și perspective privind proiectarea unei arhitecturi pentru Industria 4.0;*
- *Concluzii și observații privind dezvoltarea arhitecturii unei soluții de mentenanță predictivă în contextul Industriei 4.0.*

3.4.2. Arhitectura SOON propusă

În cadrul proiectului se urmărește tratarea și rezolvarea într-un mod inovativ a cerințelor specifice sistemelor de fabricație industrială ce cuprind procese, mașini, senzori și operatori umani, printr-o abordare bazată pe o rețea socială de agenți. În mod concret, proiectul se concentrează pe propunerea unei soluții generale care să răspundă provocărilor privind mentenanța predictivă, detectarea automată a defectării senzorilor și optimizarea fluxurilor de producție. În Fig. 8 este ilustrată arhitectura generală propusă, în care entitățile implicate sunt modelate ca elemente componente ale unei rețele sociale.

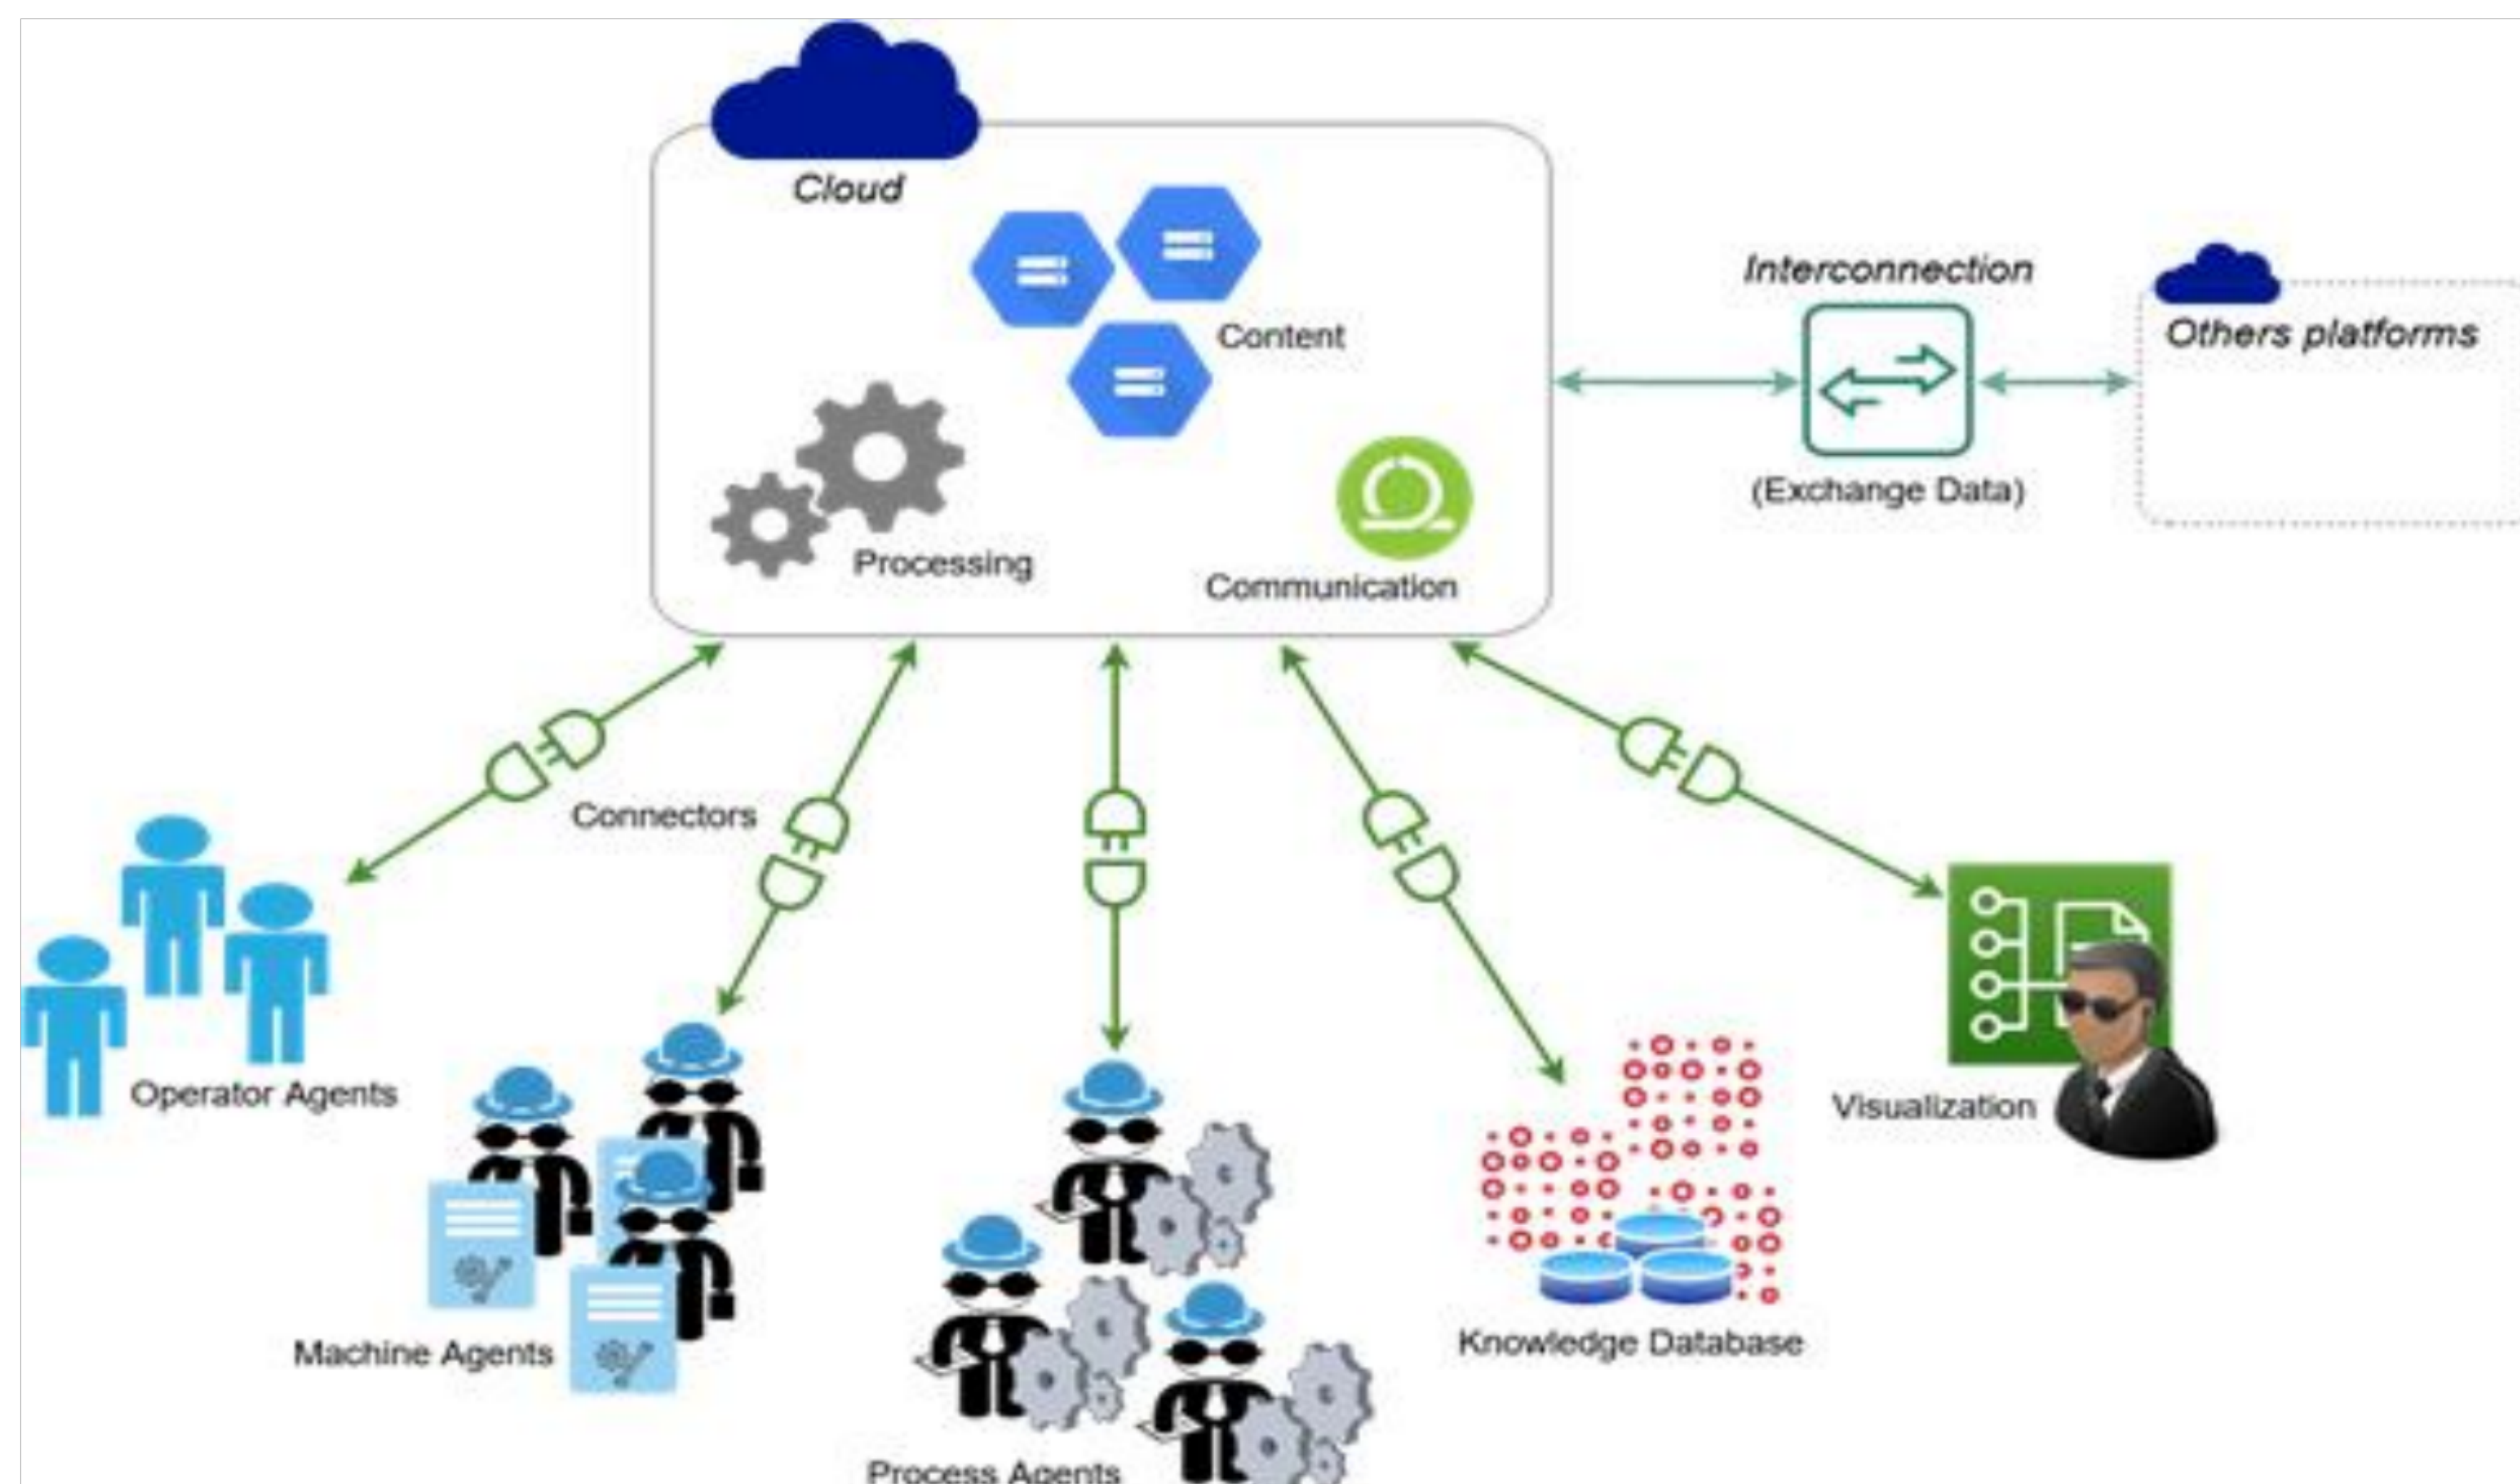


Fig. 8. Arhitectura generală SOON

Arhitectura SOON este centrată pe următoarele roluri de bază ale agenților:

- *Agent operator*: acest rol se atribuie specialiștilor umani responsabil cu operarea unei mașini/unui grup de mașini/utilaje sau a unui întreg atelier;
- *Agent mașină*: văzut ca o entitate reprezentată de un agent software autonom (un modul software, care din punct de vedere funcțional dispune de proprietăți ale agenților), care este atașat unui dispozitiv (având senzori și actuatori), unei mașini sau utilaj din lumea reală. Agentul mașină “observă” funcționarea și evoluția sistemului fizic. El este înzestrat cu un comportament social prin relaționarea cu alți agenți;
- *Agent de proces*: este similar agentului mașină, fiind în schimb asociat unui proces sau flux supervizat.

Alte componente principale în cadrul SOON sunt reprezentate de:

- *Baza de cunoștințe (Knowledge database - KD)*: care stochează diverse date, informații, cunoștințe și ontologii relevante în contextul rețelei sociale de agenți. De exemplu, KD va stoca date și informații despre defecțiunile din trecut și acțiunile de întreținere aferente. Astfel, agenții vor “interoga” KD pentru a obține referința

către acțiunea cea mai oportună de întreprins în cazul apariției unei defecțiuni sau la predicția acesteia;

- *Instrumentele de vizualizare (Visualization - VI)*: sunt utilizate de către operatori sau supervizori în vederea obținerii informațiilor utile din sistem. Pe baza cercetărilor actuale întreprinse s-a concluzionat că este foarte importantă reprezentarea vizuală a datelor ajutând operatorii umani în luarea în continuare a diferite decizii.

În cadrul arhitecturii propuse, conectorii reprezintă soluția de interfațare software care asigură interconectarea componentelor eterogene în vederea asigurării comunicării în cadrul sistemului. Componenta de tip cloud include funcționalități suplimentare celor realizate de către agenții sociali. Considerăm că aceasta cuprinde metode de prelucrare, analiză și stocare de date bazate pe tehnologii de procesare distribuită în rețea. În principiu, fiecare sistem de producție se poate baza pe propriile servicii de cloud care pot fi interconectate cu alte cloud-uri similare sau conexe pentru transferul de date, informații și cunoștințe.

3.4.3. Fluxul informațional în sistemul SOON

Modul de realizare al funcționalităților principale ale soluției SOON depind de specificul datelor brute provenite din procese industriale care se bazează pe instalații, mașini și dispozitive echipate cu senzori și, deasemenea din sisteme informatice utilizate în producție. Figura 9 prezintă fluxul de informații în cadrul framework-ului SOON. Fluxul de informații constă în următoarele: datele sunt generate de diferite surse de date, apoi sunt procesate pentru a obține informații relevante, pe baza cărora, agenții iau decizii în cunoștință de cauză și declanșează diferite acțiuni.

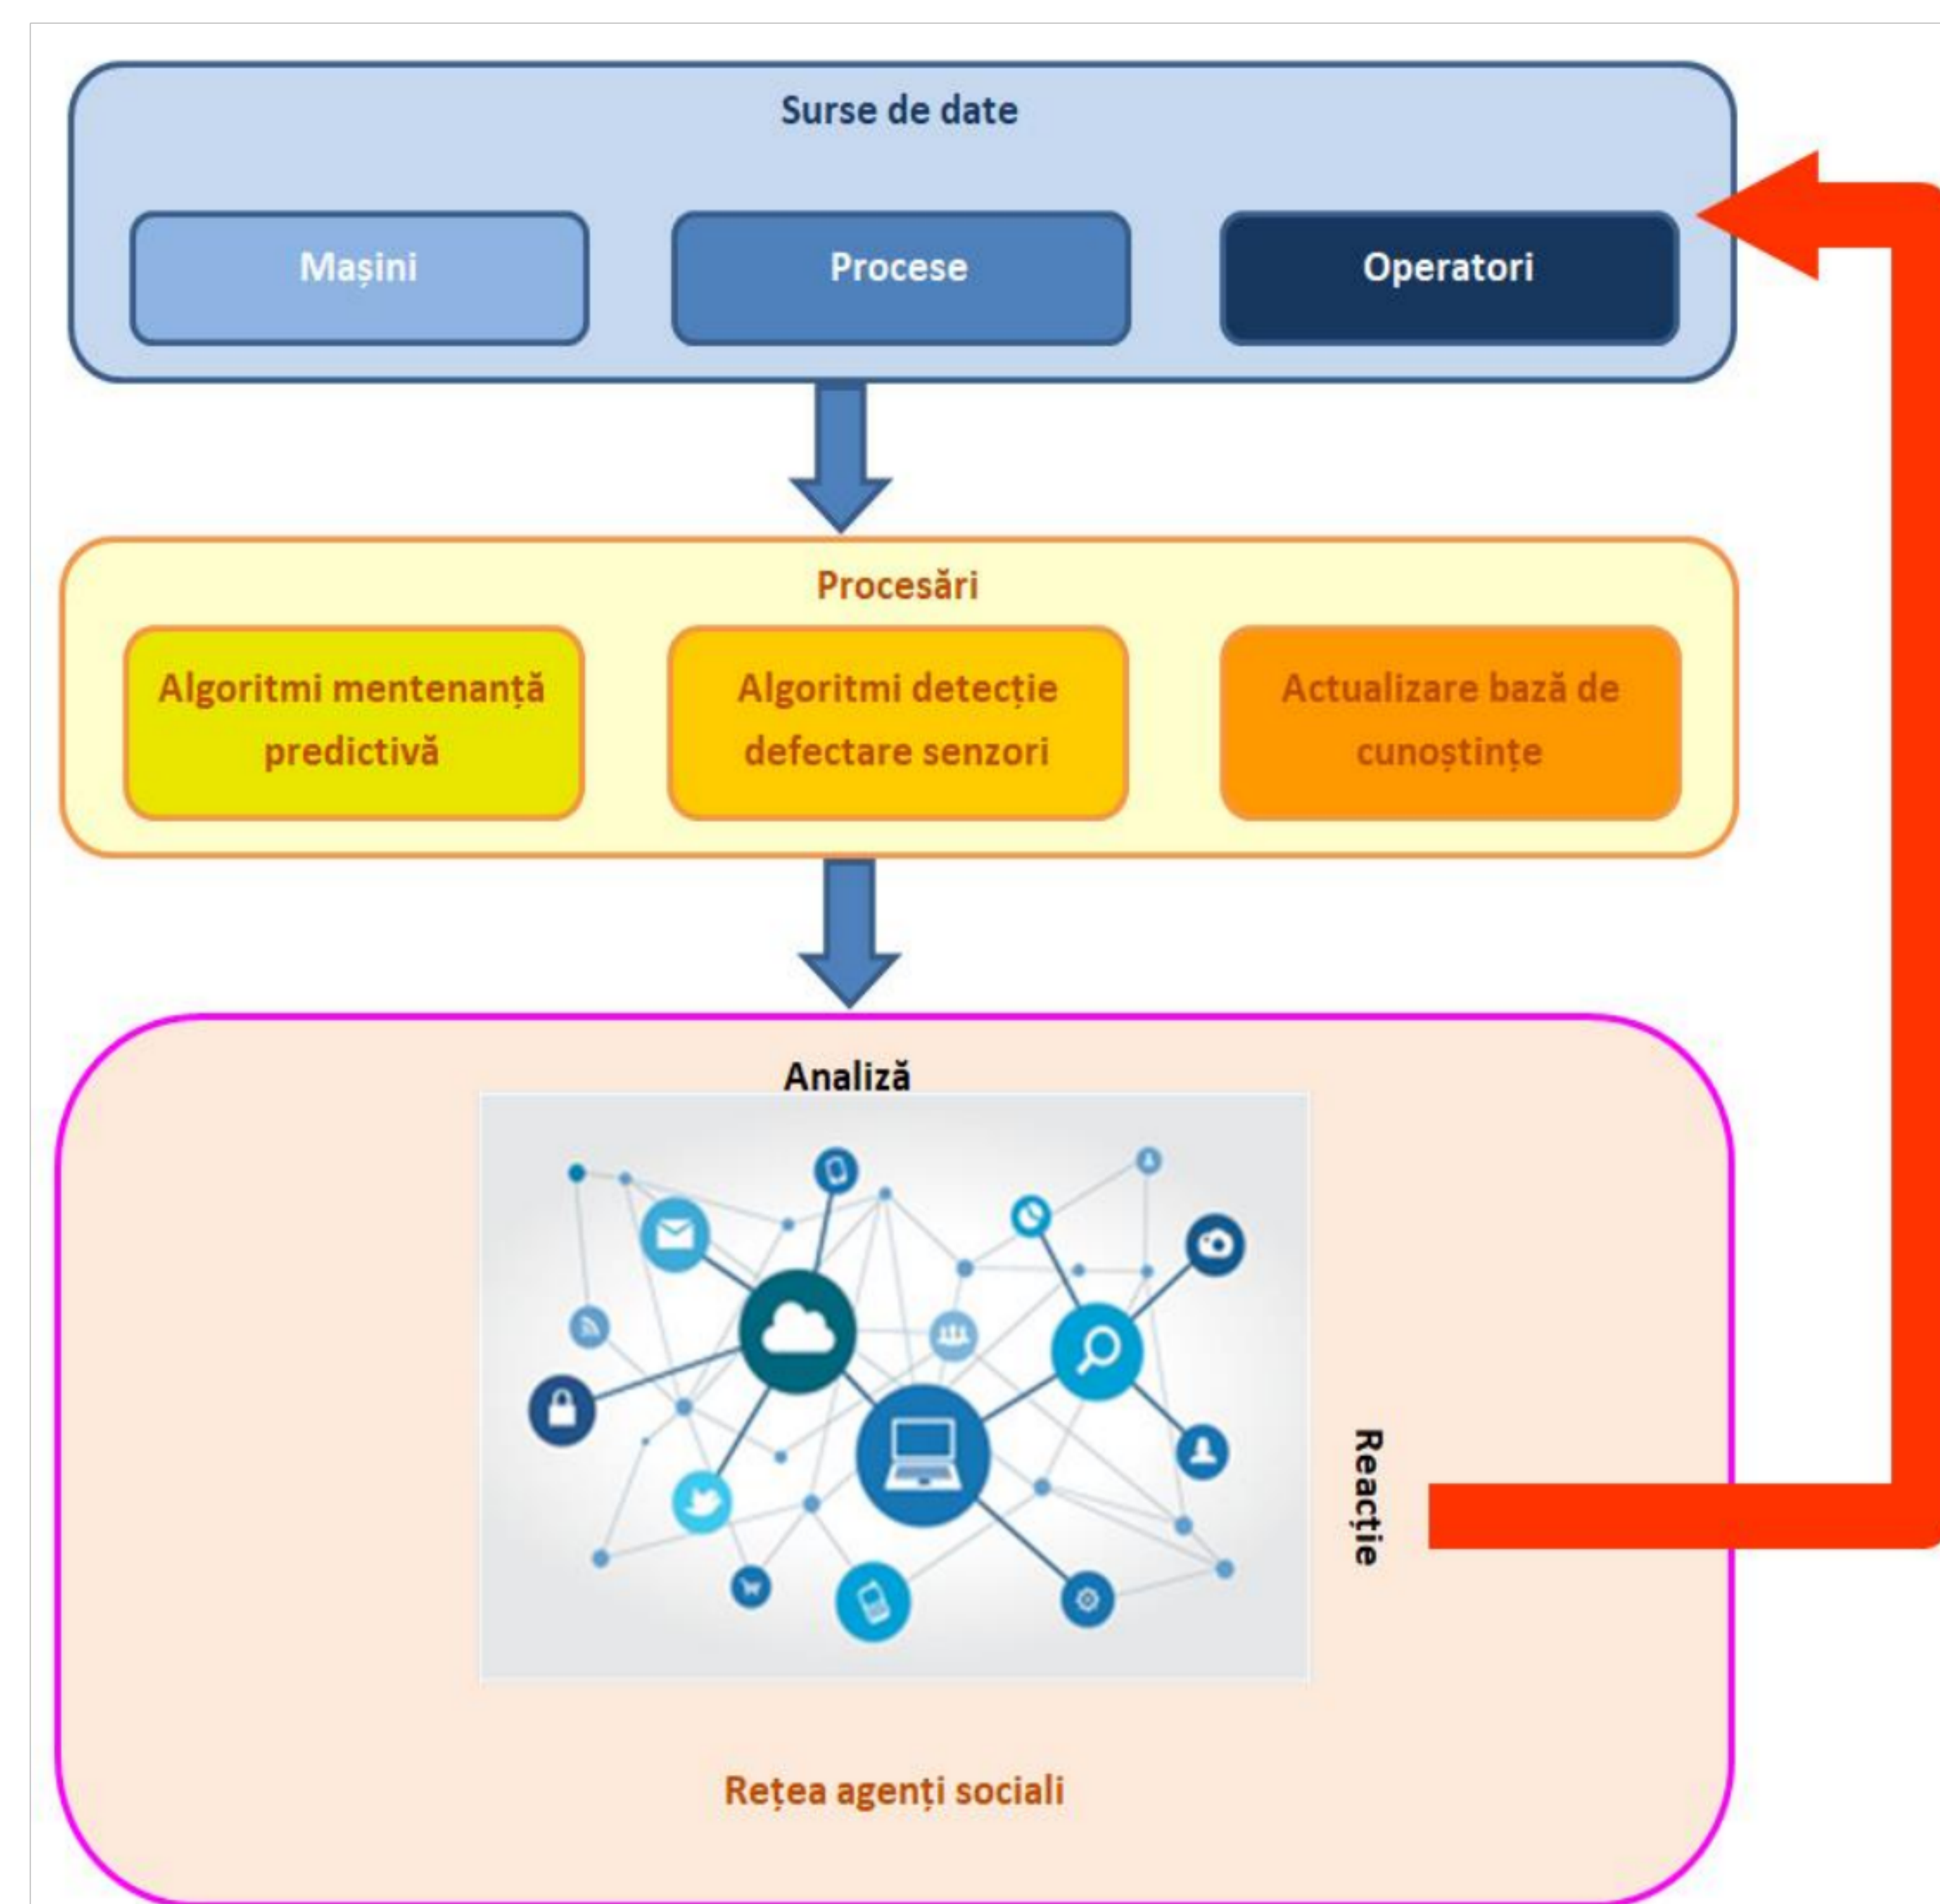


Fig. 9. Fluxul informațional în abordarea SOON

Surse de date: În cadrul SOON, datele sunt generate în principal de trei tipuri de surse de date eterogene: mașini, procese și operatori.

- *Mașini:* într-un context Industry 4.0, mașinile sunt de obicei echipate cu senzori, capabilități de calcul și pot ține evidența istoricului activităților desfășurate;
- *Procese:* informațiile despre un proces permit obținerea unei imagini de ansamblu globale a procesului industrial. În această categorie, luăm în considerare toate informațiile disponibile din cadrul soluțiilor de tip Sistem pentru planificarea resurselor întreprinderii (ERP), Sistem pentru Managementul relațiilor cu clienții (CRM) și Sistem pentru Managementul lanțului de aprovizionare (SCM);
- *Operatori:* operatorii umani interacționează cu sistemul ducând la generarea de date și informații suplimentare. De multe ori, doar o mică parte din datele și informațiile furnizate de operatori sunt vizibile pentru sistemul informațional.

Procesarea datelor: Datele generate în pasul anterior sunt procesate în scopul obținerii de informații și cunoștințe despre sistemul monitorizat.

3.4.4. Arhitectura sistemului multiagent - Modelul conceptual

Modelul conceptual al arhitecturii sistemului multiagent evidențiază cadrul general al modelului propus de rețea socială al soluției SOON, care încorporează SMA, algoritmi avansați pentru mentenanța predictivă, detectarea automată a defectării senzorilor și planificarea optimă a producției în contextul Industriei 4.0 pliată pe cerințele identificate de partenerii industriali implicați în proiect. Principalele cerințe constau în extensibilitate și scalabilitate, fiind necesară integrarea într-o soluție globală a tuturor entităților implicate. Soluția SOON implementată pe baza arhitecturii va include tehnologii noi, și diverse metode inovative cu scopul îmbunătățirii proceselor de decizie privind mentenanța și diferitele aspecte ale conducerii proceselor de producție.

Perspectiva ilustrată în Fig. 10 a *Modelului conceptual* al arhitecturii sistemului se bazează pe o descriere la nivel înalt, care pune în evidență structura abstractă a sistemului SOON, propusă pentru integrarea într-o singură paradigmă ce include date, cloud-ul și sistemele de procesare distribuită (edge computing) cu operatori umani implicați în sistemele de producție.

Arhitectura propusă este organizată pornind de la stocarea datelor provenite de la surse primare de date, ca de exemplu operatorii umani, procesele industriale ale diferitelor subsisteme și unele date stocate în cloud provenite de la sisteme informatice existente. Locațiile stocării vor fi locale (de exemplu, pe sisteme SBC) și accesate local, și în cloud prin intermediul API-urilor disponibile care permit interoperabilitatea în cloud. Tehnologiile propuse a fi integrate includ: sisteme tip *om - sistem ciber-fizic*, mediu colaborativ bazat pe cloud și nivelul sistemelor de procesare distribuită.

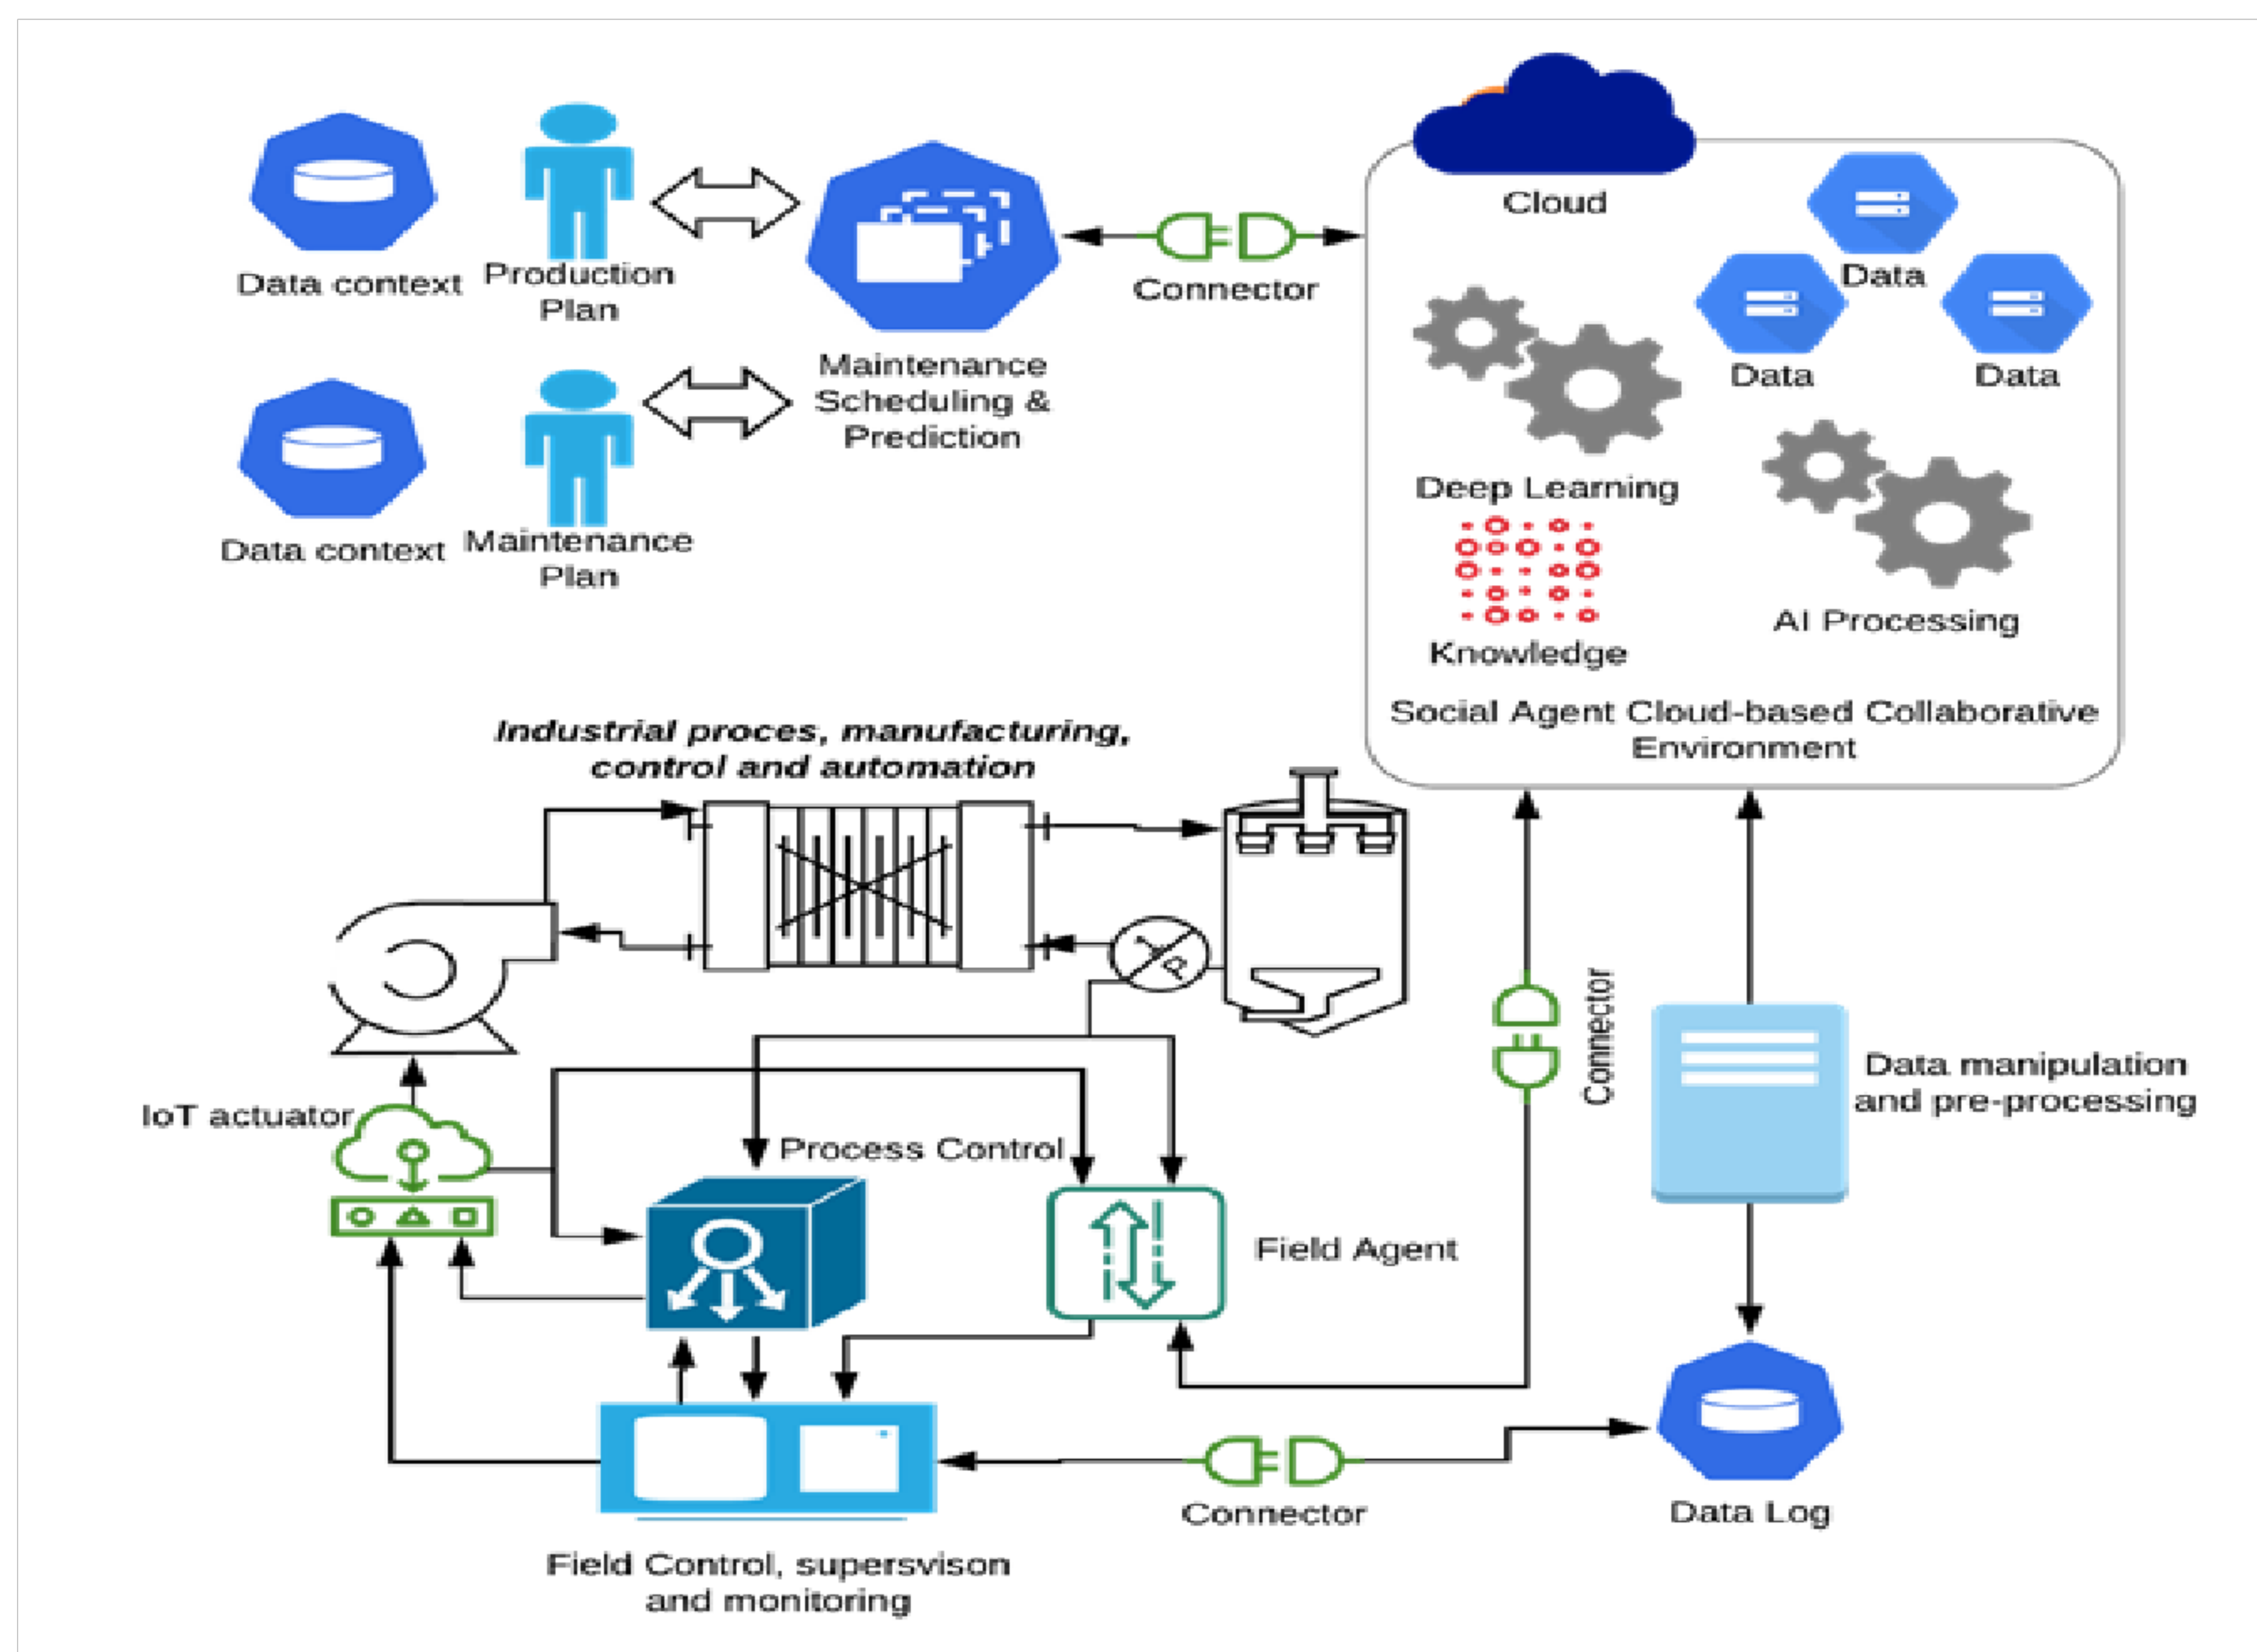


Fig. 10. Modelului conceptual al arhitecturii sistemului

Mediul de colaborare bazat pe cloud este conceput pentru a oferi schimb de date și în timp real între operatori umani, sistemele de procesare distribuită, procese și servicii precum procesări bazate pe algoritmi inteligenți, soluții de învățare automată, agregare de date și modele. Un rol important în cadrul soluției SOON îl reprezintă nivelul procesărilor distribuite (edge computing) care constă în achiziția de date, pre-procesare și stocare a datelor, alături de funcționalitățile specifice. Proiectarea sistemului social multiagent este coordonat de către partenerul academic din Slovacia sub forma livrabilului identificat la nivel de proiect ca D3.2 Rețea socială multi-agent și arhitectură de mediu colaborativ bazat pe cloud (En: Multi-agent Social Network and Cloud-based Collaborative Environment Architecture Document).

Modelul conceptual realizat pune în evidență, pe lângă aspectele menționate, fluxul de date și relația funcțională în soluția propusă SOON. În cazul modelului conceptual prezentat se evidențiază o serie de relații, care în principal urmează trei direcții: mașină/senzor/actuator - agenți sau componentele de procesare distribuită - cloud și operator - mediul colaborativ bazat pe agenți sociali integrați în cloud, după cum se poate evidenția în figura 11.

Soluția propusă permite integrarea într-o arhitectură de sistem multiagent bazată pe un cadru social elemente eterogene și hibride precum agenți, senzori, mașini, procese, componente de optimizare, servicii bazate pe cloud, operatori umani etc. În acest context, un API cu diverse interfețe pentru fiecare flux de date necesar cu specificații deschise pot acoperi cerința propusă.

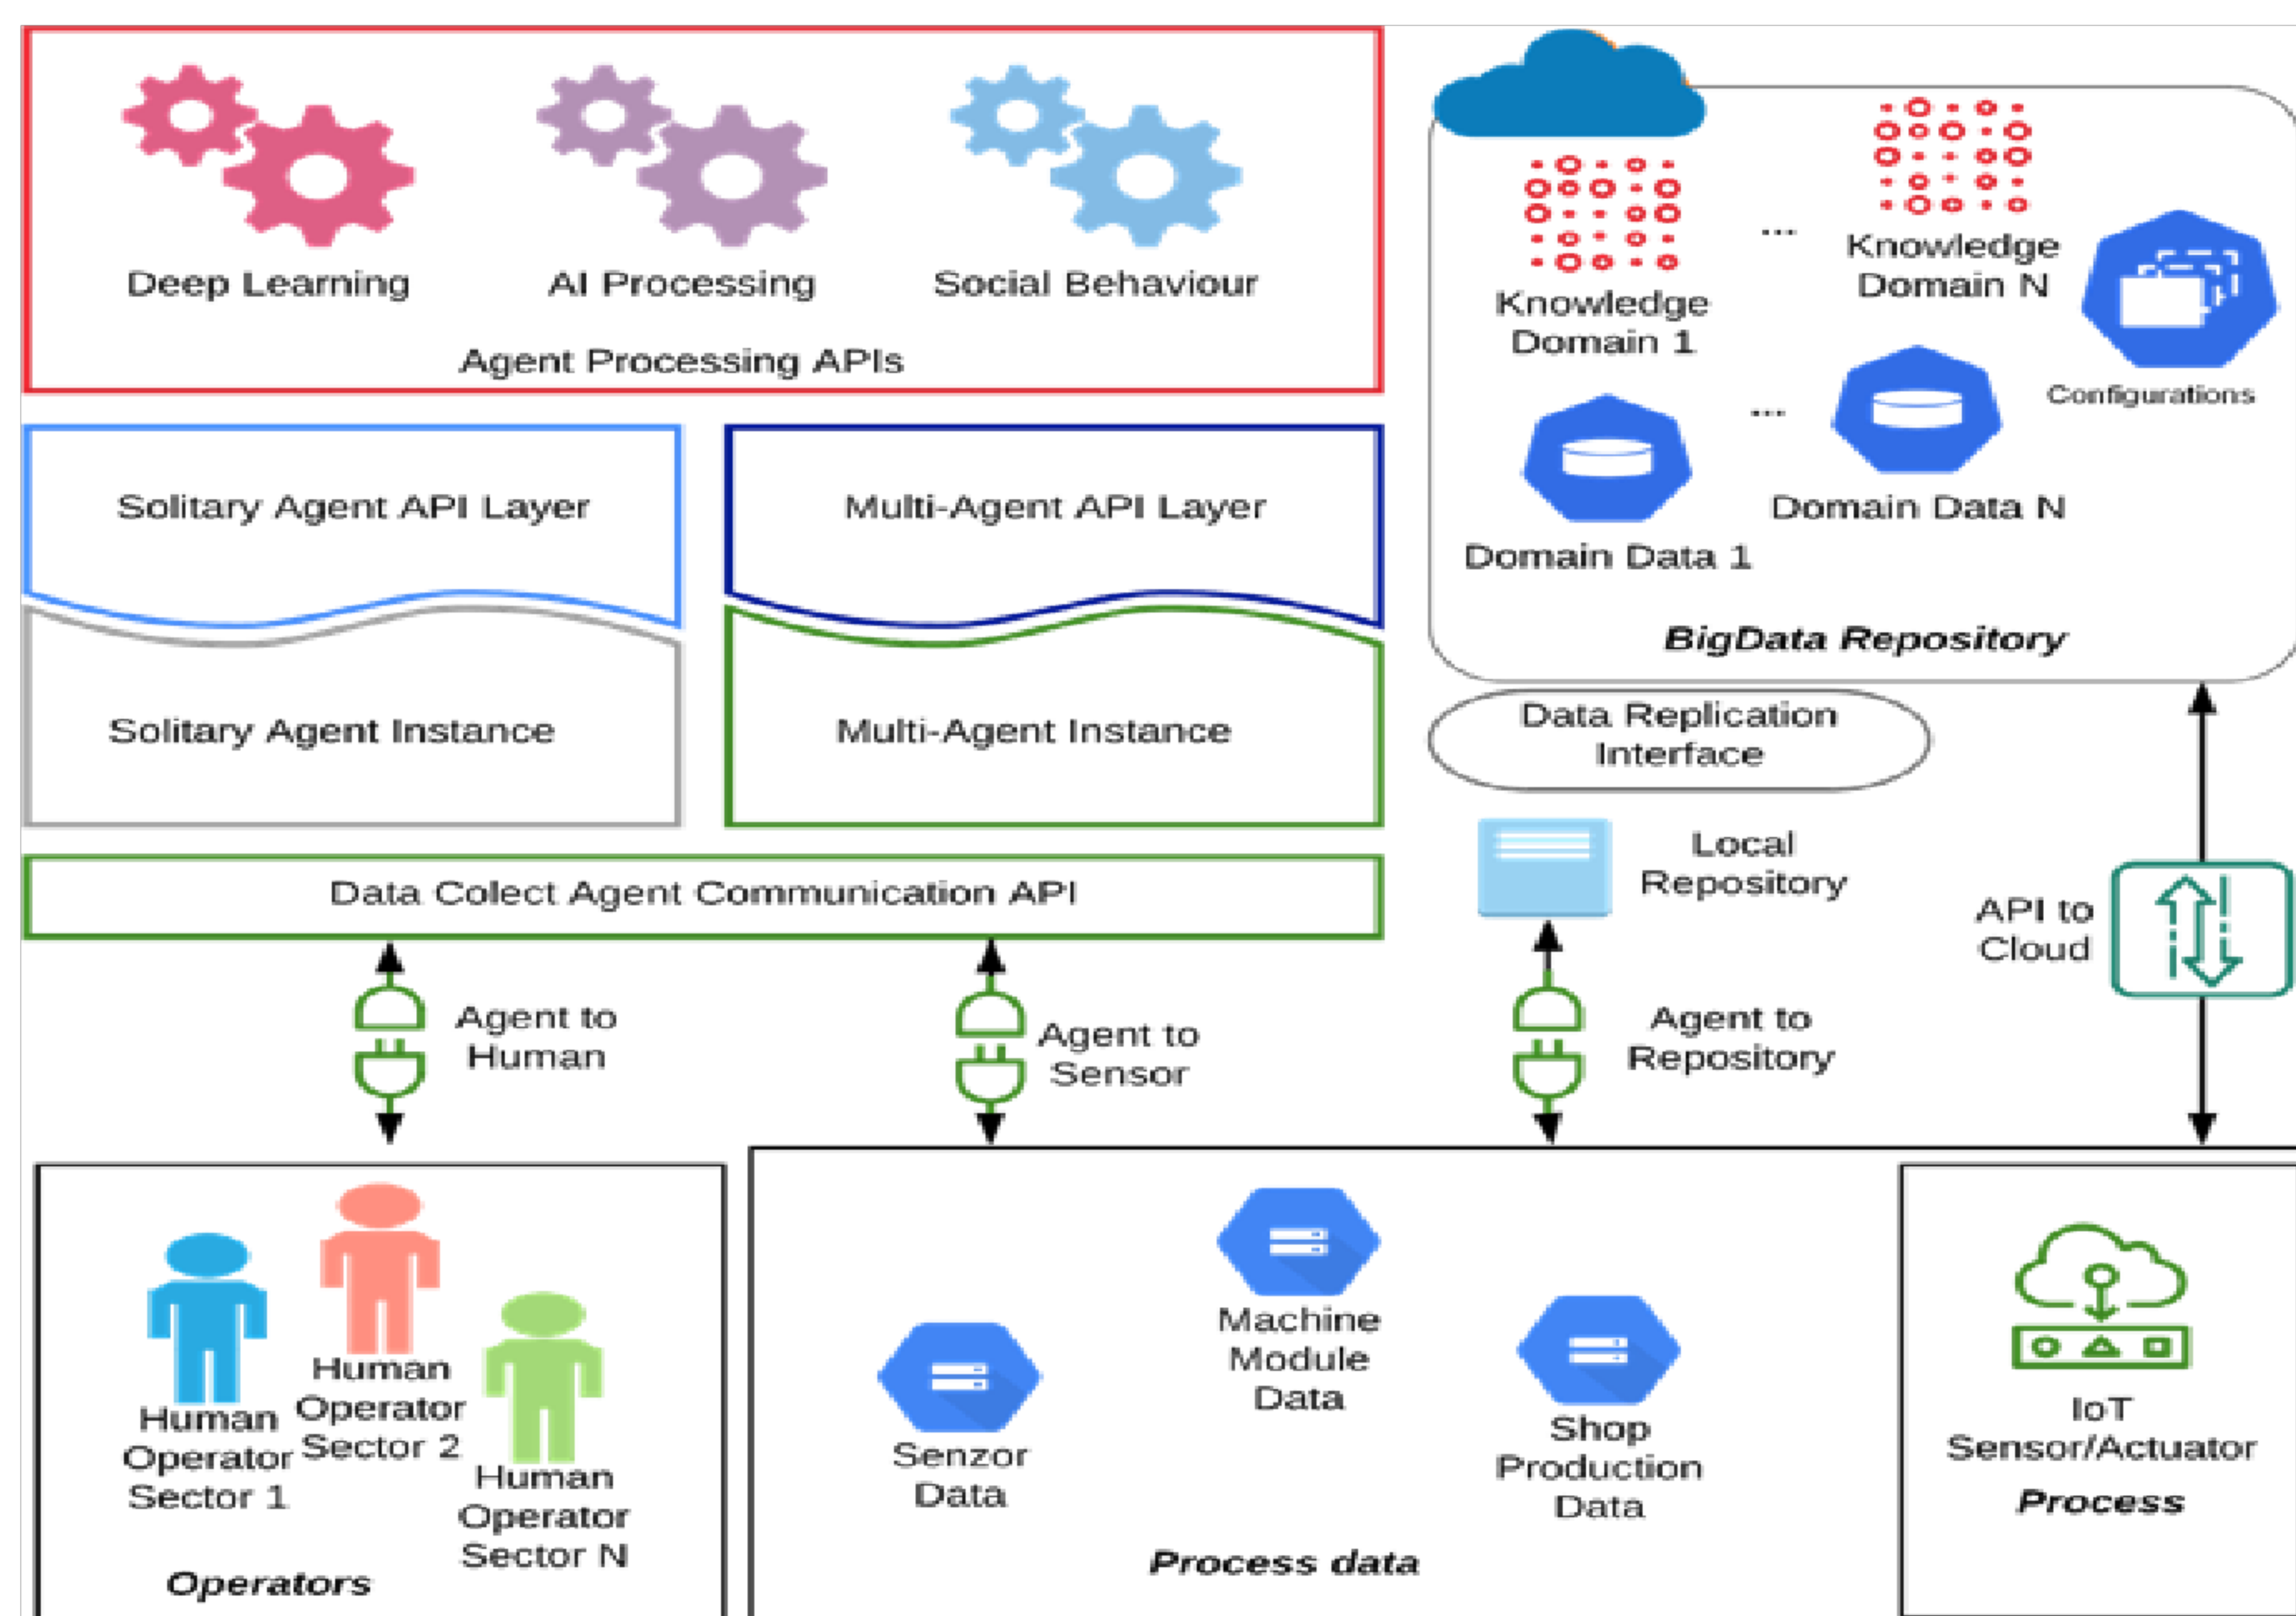


Fig. 11. Arhitectura structurii sistemului de agenți

3.4.5. Arhitectura generică de agent

Principala entitate implicată în furnizarea rezolvării problemelor bazate pe modelul rețelei sociale include unități de procesare reprezentate de agenți software sociali. Un agent software social, denumit aici pe scurt agent, în funcție de domeniul în care operează, trebuie să ia decizii optime.

Din punctul de vedere al specificului problemelor rezolvate, agenții pot să dispună de diferite specializări, de exemplu monitorizare și supraveghere, operator, etc., așa cum a fost dezvoltat în rețeaua socială multi-agent prezentat în documentul D3.2.

Structura propusă cuprinde o abordare integrată pentru procesările specifice întreținerii predictive, pentru care sunt necesare date, cunoștințe conexe și interfețe de comunicații pentru o integrare efectivă cu sistemele fizice (mașini, senzori, procese), operatori umani, alți agenți sociali și module de procesare computațională, diferite tehnologii de tip “edge computing”, baze de date și servicii de procesare distribuită (de exemplu de tip cloud și fog).

Studiul bibliografic referitor la elaborarea de ontologii a inclus lucrări de referință [Kum19, Ram20]. În abordarea noastră, în contextul agenților sociali, unele dintre cunoștințele lor și relațiile mutuale vor fi modelate folosind ontologii. Ontologiile vor integra cunoștințe și date din cazurile de utilizare. Datele necesare pentru construcția ontologiilor vor fi colectate utilizând o platformă specifică care urmează să fie dezvoltată. Ontologia generată, printre altele, va conține cunoștințe care stau la baza raționamentelor agenților în relație cu mentenanța predictivă.

3.4.6. Taxonomia agenților SOON

Provocările identificate în cerințele industriale impun sarcini specializate de rezolvat. care implică utilizarea agenților concepuți pentru efectuarea unor prelucrări specifice. În acest context, așa cum este descris în Fig. 12, agenții fac parte din clase diferite. Cu toate acestea, agenții sunt desemnați să rezolve sarcini dedicate, dar, în esență, vor împărtăși caracteristici comune, cel mai important fiind comportamentul social. În Fig. 12 este prezentată soluția SOON bazată pe propunerea privind abordarea ierarhică conceptuală a agenților. De la nivelul superior derivă ierarhic diferiți agenți cu scopuri specializate. Această ierarhie poate fi analizată prin două puncte de vedere: ale abstractizării și din perspectivă funcțională.

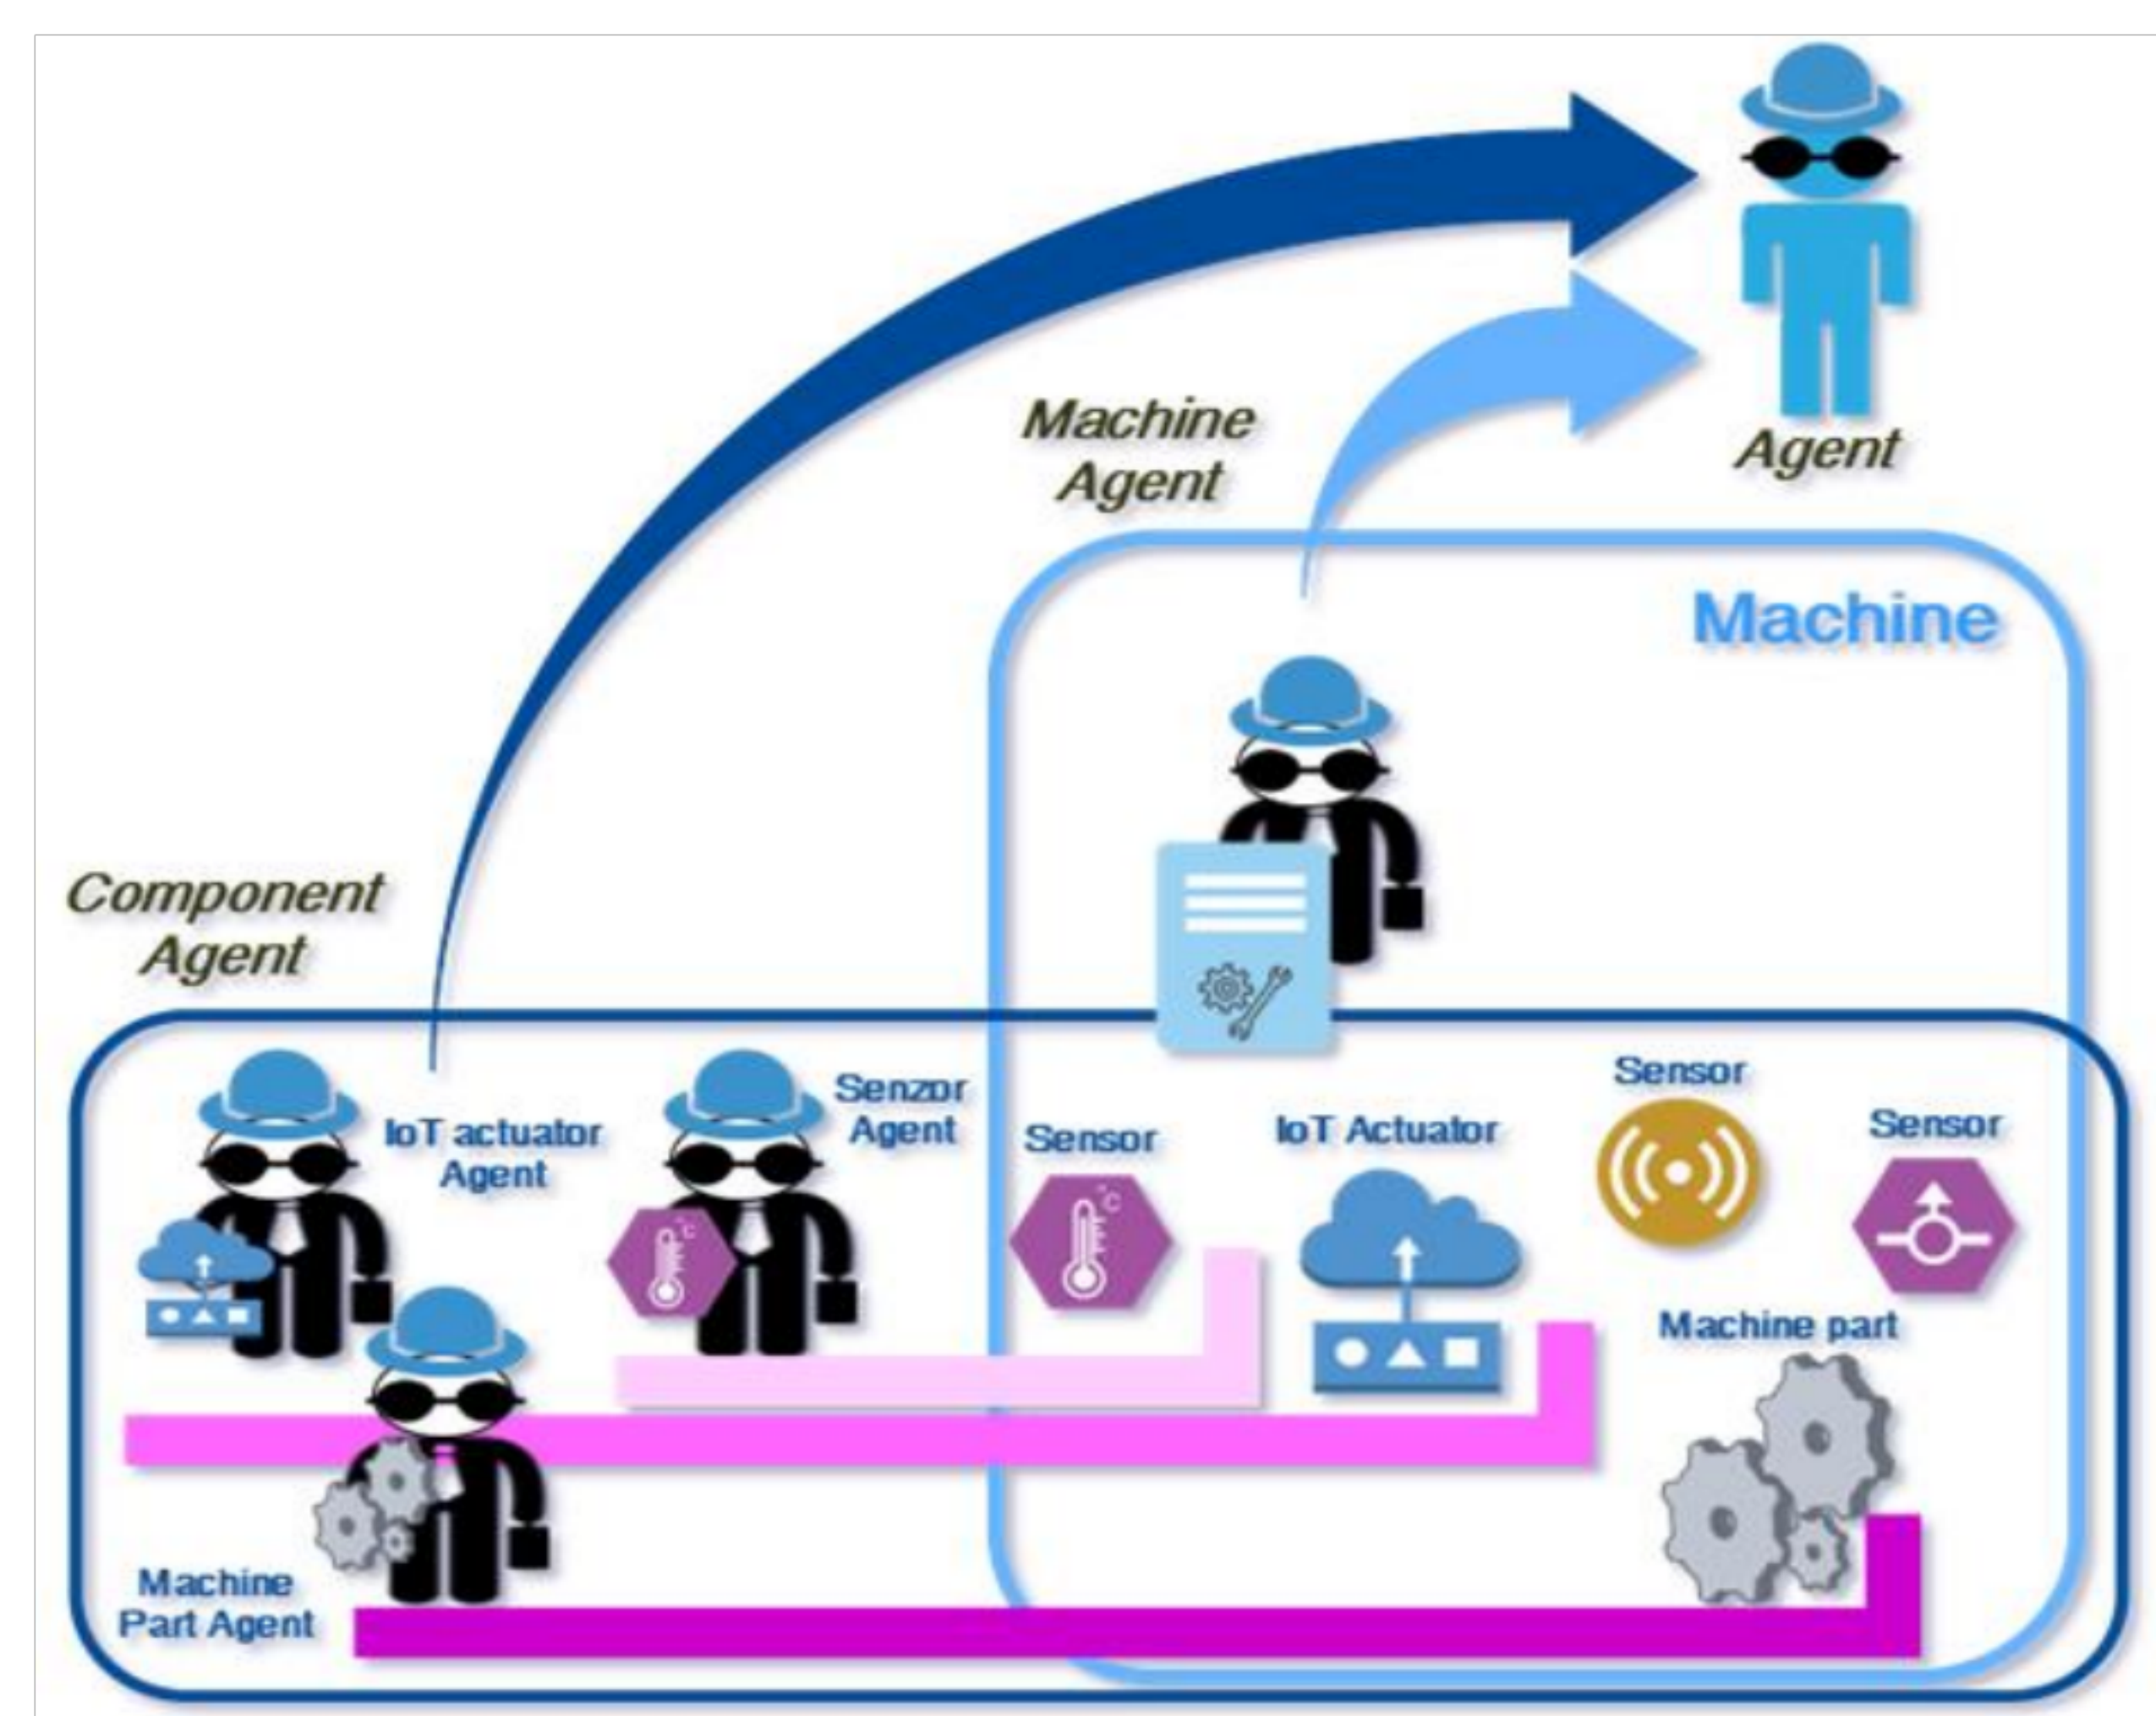


Fig. 12. Taxonomia de agenți

Mai concret, în Fig. 12 este prezentată ierarhia entităților necesare implementării soluției SOON, constând din mașinii, componente, senzori și agenți de proces. De asemenea, se poate observa abordarea pe cele două clase generalizate propuse pentru agenți, desemnate pentru a descrie locul în sistemul SOON la nivel sistemic, și anume: agent de mașină (de exemplu, mașină, proces), sau agent de nivel de câmp, și anume: agent de componentă (de exemplu, senzor, piesă de mașină, actuator, componentă IIoT, etc.).

Agenții din clasa de tip componentă sunt concepuți în principal pentru a capta stările senzorilor, pentru a interacționa cu actuatorii, cu dispozitivele IIoT și cu diferitele componente monitorizate mașini/procese. Din interacțiunea menționată rezultă sarcinile de întreținere predictivă specifice, legate de instrumente și componentele mașinilor, care se găsesc adesea în mod tradițional în mașini și sisteme de producție, de ex. strung, acționări electrice, unități de control (cum ar fi PLC-uri) etc.

Agenții din clasa mașină (agenții de tip mașină) sunt responsabili de funcționalitățile de întreținere inteligentă predictivă la nivelul mașinilor sau liniilor de producție (parte specifică ce ține de procesul de producere a produselor).

3.4.7. Concluzii referitoare la arhitectura propusă

Literatura recentă de specialitate arată că sub influența dezvoltării industriale, în special în contextul sistemelor de producție și al Industriei 4.0, au fost propuse arhitecturi generale, recunoscute de organizații internaționale prestigioase, care sunt prezentate la un nivel conceptual, fără a furniza detalii de implementare. În acest sens, propunerea și dezvoltarea unei arhitecturi adecvate pentru implementarea unei soluții de întreținere predictivă în contextul actual al adaptării la cerințele Industriei 4.0, reprezintă o necesitate reală. Pe baza acestor circumstanțe a fost dezvoltată o arhitectură de sistem care a fost documentată în livrabilul D5.1 la nivel de proiect SOON, intitulat En: “System and Architecture Specification”.

Arhitectura dezvoltată reprezintă o abordare care implică o nouă paradigmă a sistemului de fabricație văzut ca o rețea socială ce reunește pe o platformă pentru rezolvarea problemelor referitoare la mentenanța predictivă, oameni, agenți, mașini și tehnologii informaționale de ultimă oră (soluții multiagent, big data, procesări în cloud, etc.). Structura adoptată scalabilă și deschisă asigură dezvoltarea incrementală a soluției și, de asemenea, implementarea în cazurile diferitelor scenarii industriale identificate ce fac parte din diferite tipuri de industrii.

În acest subcapitol au fost prezentate pe scurt câteva aspecte referitoare la arhitectura proiectată la un nivel conceptual general, fiind prezentate și principalele specificații. Pe baza acestora va fi implementat sistemul cooperativ multiagent care va include agenți sociali, ce vor fi utilizați în rezolvarea unor probleme, axate pe mentenanța predictivă în cadrul unei platforme industriale care se conformează unui ecosistem de tip Industrie 4.0. Dezvoltarea software-ului se va baza cu precădere pe o metodologie agilă (agile software development)[Yli19]. Ceea ce presupune planificare adaptativă, dezvoltare evolutivă, îmbunătățire continuă, care de asemenea încurajează adaptarea în mod flexibil la schimbări și cerințe noi care apar pe parcurs.

3.5. Paradigme și mentenanța predictivă

În acest subcapitol sunt prezentate rezultate științifice, totodată include și un studiu bibliografic, publicate sub forma unui articol, [Vla02] în lista de referințe.

3.5.1. Consumul de energie un indicator al stării și eficienței de operare

Sistemele de producție actuală într-o măsură semnificativă depind de energia electrică, estimările [Li16] arătând că aproximativ jumătate din producția mondială este alocată acestui sector. În mod evident, se poate observa că multe aspecte, precum costurile de producție sau de exemplu impactul asupra mediului datorat acestor sisteme de producție, sunt direct legate de consumurile de energie electrică. Din acest motiv măsurarea, înregistrarea și analiza consumurilor de energie prezintă o importanță deosebită în noul context al Industriei 4.0, reprezentând sursa unor indicatori ce pot fi utilizați pentru

estimarea și mai apoi optimizarea acestor sisteme de producție. În mod direct, cuantificarea și evaluarea consumului de energie poate fi considerat ca o măsură a eficienței sistemelor de producție [Ma20]. Pornind de la acest aspect, în cazul cercetărilor noastre, s-a considerat că acest indicator poate fi extins și pentru evaluarea stării și condițiilor de funcționare a anumitor dispozitive, ansambluri, linii sau unități de producție, în vederea stabilirii strategiilor de mentenanță predictivă. Pornind de la această abordare au fost identificate două direcții principale de urmat: urmărirea și evaluarea consumurilor de energie în vederea corelării cu evenimentele de defectare, respectiv, integrarea unui astfel de sistem considerând abordarea Industry 4.0 cu problemele și provocările care derivă de aici.

3.5.2. Mentenanța predictivă prin prisma consumului de energie

Evaluarea stării echipamentelor, dispozitivelor sau utilajelor utilizate în industrie se poate realiza în mod direct și în timp real prin instalarea și citirea unor senzori adecvați fiecărei situații în parte. O astfel de abordare însă, ridică o serie de provocări, a căror soluționare este extrem de complexă și nu de puține ori și extrem de costisitoare sau în alte situații, nepractică sau ineficientă, datorită condițiilor tehnice de lucru (condiții dificile cum ar fi temperaturi ridicate, mediu cu perturbații puternice, mediu impropriu de operare, etc.). Din acest motiv nu toate situațiile permit monitorizarea directă în câmp a evoluției sistemelor de interes, prin urmare rămâne la îndemână aprecierea acestor sisteme prin evaluare indirectă, pornind de la măsurători sau observații ale unor mărimi sau semnale fizice accesibile. Evaluarea prin intermediul consumurilor de energie electrică reprezintă o abordare posibilă, pe de o parte datorită faptului că în multe situații aceasta deja este implementată, iar pe de altă parte este utilă și ca sursă primară de date pentru alte subsisteme de management.

Pentru a evalua și demonstra viabilitatea unei astfel de abordări s-a construit un stand experimental și s-a realizat o cercetare aplicativă cu suportul logistic al unui agent economic local ce s-a concretizat printr-un raport de cercetare publicat sub forma unui articol științific [Vla20].

În [Vla20] am arătat că urmărind consumurile de energie, utilizând senzori integrați în soluții inteligente de măsurare, putem evalua eficiența operării sistemelor tehnice și implicit putem determina pierderile tehnice dar mai ales și cele non-tehnice, care permit aplicarea unor măsuri necostisitoare și rapide pentru reducerea pierderilor și scăderea costurilor.

Un rezultat remarcabil este demonstrarea că prin utilizarea noului algoritm bazat pe modelul de optimizare propus și a unei modelări ce are ca punct de pornire măsurătorile din teren, se pot în mod eficient identifica și localiza punctele de consum din rețeaua monitorizată care prezintă probleme, iar prin extensie la problema de cercetare curentă, determinarea consumatorilor, care necesită intervenția imediată sau a unei viitoare intervenții de mentenanță. Modelul (1) de optimizare propus în [Vla20] este particular sistemului analizat, însă acesta poate fi extins prin introducerea coeficienților de modelare

adecvați pentru orice fel de sistem ce se poate abstractiza informațional sub forma unei rețele la care se pot urmări consumurile de energie.

3.5.3. Urmărirea consumului de energie ca soluție de mentenanță predictivă în contextul Industriei 4.0

Studiul întreprins a avut ca punct de pornire o structură ce beneficiază de un sistem de măsurare inteligent convențional. Pentru îmbunătățirea performanțelor acestui sistem s-a propus implementarea unor soluții tip IIoT și IoE care să transforme rețeaua existentă într-o rețea inteligentă, prin transformarea nodurilor sale în entități cu un anumit grad de autonomie. Comportamentul reactiv și abilitățile de comunicare adăugate, au condus la obținerea unei rețele sociale ce poate fi utilizată la rezolvarea a numeroase probleme prezentate în lucrarea [Vla19], precum reconfigurarea automată, identificarea nodurilor în care apar defecțiuni, autodiagnosticul în cazul anomaliilor de operare.

Într-o astfel de configurație algoritmul din [Vla20] rezolvă problema pentru care a fost proiectat într-o manieră eficientă, identificând și eliminând problemele de conectivitate specifică senzorilor de câmp.

3.5.4. Identificarea defectării senzorilor și a măsurătorilor eronate

Obiectivul principal al studiului s-a concentrat pe măsurarea consumurilor de energie, însă prin adaptarea la specificul modelului propus, soluția reprezintă o abordare adecvată pentru detecția defectării senzorilor sau a datelor eronate furnizate de către aceștia.

În cazul rețelelor de senzori eterogeni, modelul propus trebuie adaptat fiecărei clase de senzori, însă prin introducerea unei abordări bazate pe sisteme multiagent ce dispun de algoritmi de învățare proprii conduc la descentralizarea problemei și la înlăturarea neajunsului menționat.

Rezultatele prezentate în [Vla19] reprezintă o bază pentru implementările în cadrul SOON, fiind un prim pas care demonstrează că o abordare a sistemelor tehnice pornind de la modele bazate pe rețele sociale complexe poate conduce la rezultate promițătoare.

4. Concluzii

Apariția situației pandemice cu virusul COVID-19 a reprezentat o provocare din perspectiva implementării proiectului, dar toate obiectivele și activitățile propuse specifice etapei raportate au fost realizate cu succes. Pandemia nu a permis efectuarea unor activități planificate precum mobilități, vizite de lucru, participări on-site la conferințe. Printre altele, inițial a fost planificată participarea la Seminariile Chist-Era 2020, dar evenimentul a fost anulat de către organizatori. Colaborarea cu partenerii de proiect SOON a fost foarte bună. Lunar în cadrul proiectului SOON sunt organizate videoconferințe între toți partenerii

de proiect. Toate acestea oferă contextul necesar implementării în continuare cu succes a proiectului în etapa următoare.

A fost întărită colaborarea științifică cu proiectul FIREMAN. Au fost stabilite colaborări viitoare între cele două proiecte în ceea ce privește cercetarea, schimbul de expertiză și experiență, respectiv diverse alte activități. UMFST a fost gazda Workshop-ului Internațional Smart Technologies in Industry 4.0 (RATIONALITY), organizat la UMFST în colaborare cu suportul oferit de membrii celor două proiecte, SOON și FIREMAN. Astfel a fost posibilă realizarea unei punți între cele două proiecte prin intermediul evenimentului online și realizarea schimbului de idei într-o platformă comună.

Echipa UMFST a extins platforma pilot de testare și evaluare soluții IIoT/IIoE pentru mentenanță predictivă care a fost începută în etapa precedentă. Standul experimental construit are rolul de model fizic a unor clase de procese industriale. Standul poate fi configurat pentru modelarea și simularea diferitelor scenarii necesare obținerii unor date diversificate asemănătoare sistemelor reale din industrie. În principal, acesta va juca un rol important în Etapa a III-a, unde va fi utilizat extrem de intens, în procesele de validare a algoritmilor inteligenți de mentenanță predictivă și a testării integrării cu serviciile din cloud ale soluțiilor de mentenanță predictivă.

Patru articole elaborate în cadrul proiectului și publicate în jurnale de top au fost premiate în anul 2020. Anul acesta (mai 2020) a fost publicat un articol într-un jurnal ISI cu FI=3.275, aflat în lista de jurnale roșii (lista JCR publicată în 2020).

Cu scop de comunicare a rezultatelor către stakeholderi interesați din mediul industrial și cel academic, echipa UMFST a făcut două prezentări în cadrul Workshopului Internațional RATIONALITY.

În prezent sunt în derulare diverse cercetări pe baza cărora, în etapa următoare, se pot preconiza obținerea unor rezultate valorificabile prin comunicări la conferințe, articole în jurnale și posibil capitole de carte. Oportunitatea participării la conferințe se va evalua în funcție de evoluția pandemiei.

5. Bibliografie

[Car19]Carvalho, T.P., Soares, F.A., Vita, R., Francisco, R.P., Basto, J.P., Alcalá, S.G.: A systematic literature review of machine learning methods applied to predictive maintenance. *Computers & Industrial Engineering* 137:106024, 2019.

[Far20]Farooqui, A.; Bengtsson, K.P.; Falkman, M.F.: Towards data-driven approaches in manufacturing: an architecture to collect sequences of operations, *Int. J. of Production Research* 58(16):4947-4963, 2020.

[Gli20a]Gligor, A.; Iantovics, L.B.; Turc, A.M.: Physical Model for Electric Drive Equipped Production Unit Simulation with Edge Computing Based Monitoring Technology, *Lucre susținută în cadrul: 1st International Workshop on Smart Technologies in Industry 4.0*

- (RATIONALITY), 10 Oct. 2020 in the frame of International Conference Interdisciplinarity in Engineering (INTER-ENG 2020).
- [Gli20b] Gligor, A.; Vlasa, I.; Dumitru, C.D.; Moldovan, C.E.; Damian, C.: Power Demand Forecast for Optimization of the Distribution Costs, Proc. of 13th Intl. Conf. on Interdisciplinarity in Engineering, 3-4 oct. 2019, *Procedia Manufacturing* 46:384-390, 2020.
- [Kum19]Kumar, V.R.S.; Khamis, A.; Fiorini, S.; et al., Ontologies for Industry 4.0, *Knowledge Engineering review* 34:e17, 2019.
- [Li16] Li, Z.; Yang, H.; et al., Unrelated parallel machine scheduling problem with energy and tardiness cost, *Int J Adv Manuf Technol*, 84:213–226, 2016. <https://doi.org/10.1007/s00170-015-7657-2>.
- [Ma20] Ma, S. et al., Big data driven predictive production planning for energy-intensive manufacturing industries, *Energy*, 211:118320, 2020. <https://doi.org/10.1016/j.energy.2020.118320>.
- [Vla19]Vlasa, I., Gligor, A., Dumitru, C. D., Turc, A. M. Integrated Remote Reading Solution of Smart Metering Devices. In 2019 International Conference on Electromechanical and Energy Systems (SIELMEN), IEEE Press, pp. 1-5. 2019. IEEE. doi: 10.1109/SIELMEN.2019.8905910.
- [Vla20]Vlasa, I.; Gligor, A.; Dumitru, C.D.; Iantovics, L.B.: Smart Metering Systems Optimization for Non-Technical Losses Reduction and Consumption Recording Operation Improvement in Electricity Sector, *Sensors* 20(10):2947, 2020. <https://doi.org/10.3390/s20102947>.
- [Ram20] Ramirez-Duran, V.J.; Berges, I., Illarramendi, A. ExtruOnt: An ontology for describing a type of manufacturing machine for Industry 4.0 systems, *Semantic web* 11(6):887-909, 2020.
- [Zon20] Zonta, T.; da Costa, C.A.; da Rosa Righi, R.; de Lima, M.J.; da Trenidade, E.S.; Li G.P.: Predictive maintenance in the Industry 4.0: a systematic review. *Computers & Industrial Engineering* 150:106889, 2020.
- [Yan] Yan, H., Wan, J., Zhang, C., Tang, S., Hua, Q., Wang, Z.: Industrial big data analytics for prediction of remaining useful life based on deep learning. *IEEE Access* 6:17190–17197, 2018.
- [Yli19]Yli-Ojanperä, M.; Sierla, S.; Papakonstantinou, N.; Vyatkin, V. Adapting an agile manufacturing concept to the reference architecture model industry 4.0: A survey and case study. *J. of Industrial Information Integration* 15:147-160, 2019.
- [Tru19]Trunzer, E., Calà, A., Leitão, P., Gepp, M., Kinghorst, J., Lüder, A., Schauerte, H., Reiferscheid, M., Vogel-Heuser, B. System architectures for Industrie 4.0 applications, Derivation of a generic architecture proposal, *Production Engineering*, 13:247–257, 2019.