

UNIVERSITATEA “POLITEHNICA” DIN BUCUREȘTI
Facultatea de Automatică și Calculatoare

ANALIZA CENTRULUI DE GRAVITATE
FOLOSIND
DISCIPLE-RKF/COG

Roșu-Cojocaru Andrei
352 C3

CUPRINS

	<u>pag.</u>
Rezumat	2
INTRODUCERE	
1 - problema centrului de gravitate	4
- ce este un sistem expert ?	
PREZENTAREA SISTEMULUI EXPERT	
2 Principii de Proiectare a Agentului “Disciple-RKF”	6
Arhitectura Agentului Instructibil	7
PROGRAMUL CARE IMPLEMENTEAZA SISTEMUL EXPERT	
Generalități	8
Reprezentarea Cunoștințelor ce Pot Fi Învățate	12
- principii de proiectare	
3 Modelarea, Învățarea și Rezolvarea de Probleme Bazate pe Inițiativa Mixtă	
- Învățarea Regulilor	15
- Rafinarea Regulilor	20
- principii de proiectare	
Rezolvarea de Probleme	24
AVANTAJE ȘI DEZAVANTAJE ALE SISTEMULUI EXPERT	25
4 - Avantaje	
- Dezavantaje	
APLICAȚII ALE SISTEMULUI EXPERT	27
Utilizarea Disciple-RKF/COG în cursul	
5 “Studii de Caz în Analiza Centrului de Gravitate”	
Utilizarea Disciple-RKF/COG în cursul	
“Aplicații Militare ale Inteligenței Artificiale”	
6 DEMO. O SESIUNE SCRISA PENTRU SISTEM	29
7 CONCLUZII ȘI PLANURI DE VIITOR	32

Rezumat

Referatul prezintă rezultatul cercetărilor ce s-au desfășurat în perioada 1998-2002 în cadrul Laboratorului de Agenți Instructibili din cadrul Universității “George Mason”, a Centrului de Conducere Strategică și a Departamentului pentru Strategie, Planificare și Operațiuni Militare din cadrul Colegiului Militar al Armatei Statelor Unite. Particularitatea colaborării dintre cele trei instituții o reprezintă integrarea cercetărilor din domeniul inteligenței artificiale în strategiile militare și utilizarea practică a agenților inteligenți în educație.

Cercetările s-au concentrat în direcția a trei obiective, fiecare fiind caracteristic unei instituții din cele enumerate mai sus.

Din punctul de vedere al inteligenței artificiale, obiectivul îl reprezintă dezvoltarea abordării “discipol” pentru a construi sisteme instructibile bazate pe cunoștințe (agenți instructibili¹). Abordarea “discipol” presupune crearea unui mediu de învățare puternic care poate fi învățat de o persoană să rezolve probleme la fel de ușor cum poate fi învățat un om, încercând să schimbe modul în care agenții inteligenți sunt proiectați de la *a fi programați* la *a fi învățați* de către un utilizator care nu are o pregătire prealabilă în domeniul științei calculatoarelor. Astfel, își va putea proiecta un asistent inteligent la fel de ușor cum utilizează un editor de text pentru a redacta o lucrare.

Din punctul de vedere al strategiei militare, obiectivul îl reprezintă clarificarea și formalizarea procesului de analiză al centrului de gravitate utilizând paradigma reducerii sarcinilor generale pentru rezolvarea problemelor. Conceptual, în anul 1832, Karl von Clausewitz a introdus noțiunea de centru de gravitate pentru o entitate (stat, alianță, coaliție sau grup) ca fiind “fundăția capacității, centrul puterii și mișcării de care depinde totul, punctul către care întreaga energie ar trebui să fie direcționată”. Așadar, identificarea corectă a centrelor de gravitate a forțelor inamice capătă importanța cea mai mare într-un conflict.

Din punct de vedere educațional, obiectivul îl reprezintă îmbunătățirea procesului educațional al ofițerilor prin utilizarea tehnologiei agenților instructibili.

Cercetările s-au finalizat cu elaborarea unui mediu de învățare inteligent denumit “Disciple-RKF/COG” (“Rapid Knowledge Formation for Center of Gravity Problem” – Formarea Rapidă a Cunoștințelor pentru Problema Centrului de Gravitate) care face parte din familia Discipolilor (medii de învățare avansate).

Referatul prezintă modul în care mediul de învățare interacționează cu expertul pentru a-și construi baza de cunoștințe prelucrând și interpretând informațiile primite dar și modul în care este utilizat la cursul “Studii de Caz în Analiza Centrului de Gravitate” de la Colegiul Militar al Armatei Statelor Unite unde reprezintă un asistent inteligent pentru învățarea conceptului de analiză a centrului de gravitate și dezvoltarea unui raport privind analiza centrului de gravitate pentru un scenariu de conflict militar.

În ceea ce privește interacțiunea cu expertul, mediul de învățare inteligent “Disciple-RKF/COG” se bazează pe un mediu de învățare general “Disciple-RKF” care conține un set de module de achiziții de cunoștințe, de învățare, de rezolvare de probleme pentru o bază de cunoștințe care are două componente : un ontologie de obiecte care definește termeni într-un domeniu specific de aplicație și o mulțime de reguli de reducere a sarcinilor exprimate cu acești termeni. “Disciple-RKF” implementează mecanisme

¹ am preferat utilizarea sintagmei “agenți instructibili” în locul consacratei “agenți inteligenți” pentru că este mai puțin ambiguă (din punctul meu de vedere)

puternice de reprezentare a cunoștințelor și de raționament și, cel mai important, module care permit expertului să realizeze sarcini suplimentare privind ingineria cunoștințelor cum ar fi : specificarea de scenarii, modelarea procesului de rezolvare a problemei, formalizarea sarcinii.

În general, procesul de dezvoltare a unui agent specific bazat pe cunoștințe folosind “Disciple-RKF” presupune două etape :

- 1) dezvoltarea ontologiei de obiecte de către inginerul de cunoștințe și expert
- 2) pregătirea de către expert

În etapa 1 de dezvoltare un inginer de cunoștințe lucrează cu un expert pentru specificarea tipurilor de probleme care vor fi rezolvate, clarificarea modului în care paradigma de reducere a sarcinilor poate fi utilizată pentru rezolvarea problemelor și dezvoltarea ontologiei de obiecte (ontologia de obiecte constă într-o descriere ierarhică de obiecte și proprietăți reprezentate sub formă de cadre, așa cum este descris în protocolul “conectivității deschise a bazelor de cunoștințe” de Chaudhri în 1998). Rezultatul etapei 1 îl reprezintă un agent instructibil într-un domeniu specificat.

În etapa 2 de dezvoltare agentul este pregătit să rezolve probleme de către un expert, cu asistență limitată din partea inginerului de cunoștințe. Pașii pe care expertul îi urmează în pregătirea sistemului inteligent (folosind ontologia de obiecte, scenariile, sarcini generale și reguli) sunt : specificarea scenariului, modelarea raționamentului expertului, învățarea de sarcini și reguli, rafinarea de sarcini, reguli și ontologii și rezolvarea de probleme.

După ce “discipolul” a fost pregătit, poate fi utilizat în modul independent de rezolvare de probleme pentru identifica și testa candidați de centre de gravitate strategice pentru un scenariu nou.

În ceea ce privește modul de utilizare la cursul de “Studii de Caz în Analiza Centrului de Gravitate” la Colegiul Militar al Armatei Statelor Unite pentru a realiza o analiză a centrului de gravitate pe un scenariu specificat de conflict militar, etapele sunt : identificarea, studiul și descrierea aspectelor unei campanii care sunt relevante pentru analiza centrului de gravitate (răspunsurile primite de mediul de învățare sunt date în limbaj natural). Se pot specifica întrebări suplimentare care să nuanțeze specificarea caracteristicilor scenariului propus, însă utilizatorul nu este obligat să răspundă la toate aceste întrebări. În orice moment, “discipolul” poate fi interogat să identifice și să testeze candidații pentru centrele de gravitate strategice în condițiile specificației curente.

Raportul generat în final de “discipol” conține două părți : o parte care conține descrierea scenariului pe baza informațiilor primite de la utilizator și o parte care conține lista de candidați pentru centre de gravitate strategice împreună cu regulile care au dus la selectarea candidatului respectiv astfel încât utilizatorul, având o experiență militară unică și bazându-se pe un raționament subiectiv să poată identifica centrul de gravitate.

1 INTRODUCERE

Problema Centrului de Gravitate

Literatura militară face distincția între trei niveluri de conflicte : un nivel strategic care se ocupă de câștigarea războaielor, un nivel operațional care se ocupă de câștigarea campaniilor și un nivel tactic care se ocupă de câștigarea bătăliilor. Una dintre cele mai dificile probleme cu care se confruntă în ultimul timp conducătorii militari la nivelul strategic o reprezintă determinarea și analiza centrelor de greutate pentru forțele aliate și pentru forțele inamice. Inițial introdus de Clausewitz în lucrarea sa clasică “Despre război” (apărută în 1832), conceptul de centru de gravitate se referă astăzi la “acele caracteristici, capacități și/sau locații din care derivă libertatea de acțiune, puterea fizică sau voința de luptă pentru o forță militară” (Întâlnirea strategilor militari, 2001). Scopul forței militare ar trebui să fie eliminarea sau influențarea centrului de gravitate strategic al inamicului precum și apărarea adecvată a centrului de gravitate propriu.

Determinarea centrului de greutate se face pe baza unei game largi de cunoștințe, nu numai din domeniul militar, ci și din domeniul politic, psihosocial, economic, geografic, demografic, istoric, internațional cât și din alte domenii. În plus, situația, adversarii implicați în conflictul militar, obiectivele acestora precum și capacitățile lor pot varia într-un mod important de la un scenariu la altul. De aceea, atunci când se realizează o analiză a centrului de gravitate, experții se bazează pe experiența lor profesională și pe intuiție, fără a urmări un algoritm precis, stabilit apriori, fără a urma o abordare riguroasă. Recunoscând aceste dificultăți, Centrul pentru Conducere Strategică din cadrul Colegiului Militar al Armatei Statelor Unite au început în 1993 un proiect care avea ca scop formalizarea cunoștințelor a unui număr de experți în analiza centrului de gravitate. Această cercetare s-a concretizat printr-o monografie a analizei centrului de gravitate (Giles și Galvin, în 1996) care a oferit o bază pentru utilizarea sistemului expert Disciple în acest domeniu de aplicație valoros și pentru dezvoltarea agentului instructibil Disciple-RKF/COG.

Abordarea în analiza centrului de gravitate, bazată pe rezultatele cercetărilor lui Strange (1996) și Giles și Galvin (1996), dezvoltată cu experți de la Colegiul Militar al Armatei Statelor Unite, constă în două etape principale : identificarea și testarea. În timpul etapei de identificare, candidații pentru centrul de gravitate din categorii diferite ale puterii unei forțe militare (cum ar fi guvernul, armata, populația și economia) sunt identificați. De exemplu, un conducător puternic este un candidat pentru centrul de gravitate raportat la guvernul forței militare. Apoi, în cadrul etapei de testare, fiecare candidat este analizat pentru a se determina dacă satisface toate caracteristicile critice care sunt necesare pentru a fi centrul de gravitate. De exemplu, un conducător are nevoie să fie apărut, să fie informat, să comunice (cu guvernul, cu armata și cu populația), să fie influent (în cadrul guvernului, în cadrul armatei și în cadrul populației), să aibă forță de conducere, să aibă sprijin (din partea guvernului, din partea armatei și din partea populației) și să fie de neînlocuit. Pentru fiecare caracteristică, trebuie să se determine existența unor condiții esențiale, resurse și scopuri care sunt cerute pentru a fi total operativă și care dintre acestea, în cazul în care există, reprezintă vulnerabilități critice.

Ce este un sistem expert ?

În general, un sistem expert este compus dintr-o bază de cunoștințe și un motor de inferență cu ajutorul căruia se realizează căutări și se prelucrează informațiile din baza de cunoștințe.

Agentul instructibil este construit într-o manieră astfel încât să interacționeze cu două tipuri de entități : un expert în domeniu și un inginer de cunoștințe. Expertului în domeniu îi va furniza rezultate pe baza căutărilor și prelucrărilor realizate de motorul de inferență în baza de cunoștințe, construită de către inginerul de cunoștințe care o programează. Între inginerul de cunoștințe și expertul în domeniu există un dialog continuu bilateral. Expertul în domeniu încearcă să îi explice inginerului de cunoștințe modul în care gândește și modul în care rezolve problema astfel încât acesta să poată codifica aceste informații în acord cu modul de reprezentare a informațiilor în baza de cunoștințe și astfel să poată programa agentul instructibil. Totuși, reprezentarea cunoștințelor este un proces îndelungat și dificil ca și modelarea informațiilor primite de la expertul în domeniu. În inteligența artificială, această problemă poartă denumirea de “constrângerea achiziției de cunoștințe”.

În Figura 1 este reprezentată interacțiunea dintre expertul în domeniu, inginerul de cunoștințe și agentul instructibil :

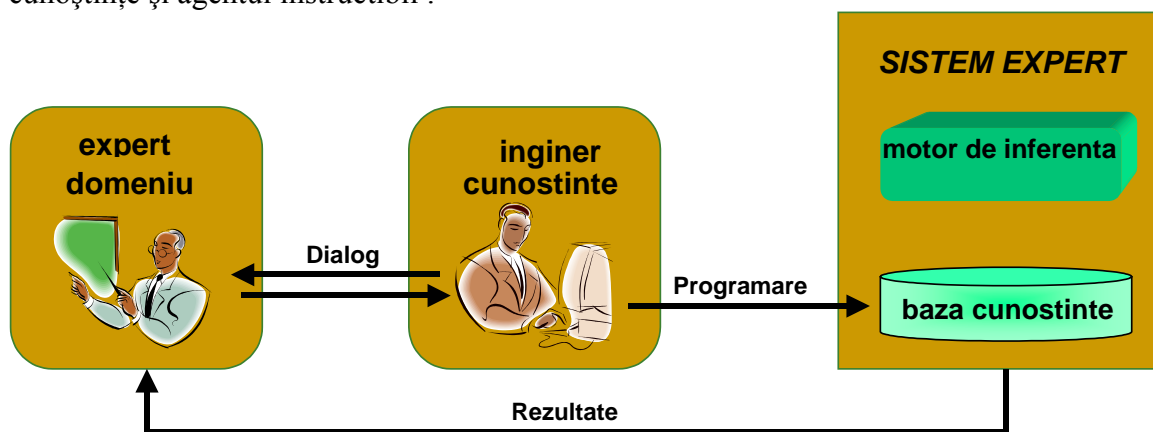


Figura 1

Plecând de la aceste premise, se dorește să se elaboreze o teorie, o metodologie și o familie de agenți instructibili orientați pe cunoștințe de către experți în domeniu **cu asistență limitată din partea inginerilor de cunoștințe**. Soluția o reprezintă dezvoltarea unui agent de învățare cărui să i se poată preda direct de către un expert în timp ce rezolvă probleme prin cooperare. Expertul în domeniu învață agentul instructibil să realizeze sarcinile așa cum ar învăța o persoană. Agentul instructibil învață de la expertul în domeniu construind, verificând și îmbogățind baza de cunoștințe. Având în vedere acest fapt, structura agentului instructibil se va modifica în sensul în care acesta va îngloba o interfață pentru interacțiunea cu expertul în domeniu, motorul de inferență având componente orientate pe rezolvare de probleme și pe învățare, iar baza de cunoștințe va reține atât ontologii cât și reguli.

În acest context, sistemul expert va trebui să fie capabil să îndeplinească următoarele sarcini : rezolvare de probleme bazată pe inițiativa mixtă, predare și învățare precum și învățare multistrategică.

2 PREZENTAREA SISTEMULUI EXPERT

Sistemul expert "Disciple-RKF/COG" are ca scop identificarea centrului de gravitate în cadrul unui conflict militar. Pentru aceasta este necesar ca un expert în domeniu să pregătească agentul instructibil prin descrierea de diverse scenarii de conflicte militare (folosind o terminologie specifică cunoscută agentului instructibil de către inginerul de cunoștințe) și prin expunerea modului de raționament pentru rezolvarea problemei centrului de gravitate. În procesul de pregătire, agentul instructibil și expertul în domeniu colaborează astfel încât să se poată dezvolta un set de sarcini și un set de reguli care vor putea fi aplicate pentru găsirea centrului de gravitate pentru un nou scenariu de conflict militar. După ce sistemul expert a fost pregătit, învățând atât din scenariile prezentate cât și din propriul său mod de raționament prin aplicarea sarcinilor și regulilor deduse relativ la scenariile prezentate pe care l-a comparat apoi cu modul de raționament al expertului în domeniu, acesta poate fi utilizat pentru identificarea centrului de gravitate în orice conflict militar.

Agentul instructibil "Disciple-RKF/COG" poate fi utilizat de către strategii militari implicați într-un conflict armat cât și de studenți ai academiilor militare care își pot testa abilitățile de a identifica centrul de gravitate strategic, comparând atât rezultatele obținute cât și modul de raționament propriu cu modul de raționament al sistemului expert. "Disciple-RKF/COG" este util din mai multe puncte de vedere. El oferă un set de candidați pentru centrul de gravitate al unui conflict militar din care utilizatorul poate alege centrul de gravitate strategic în funcție de caracteristicile scenariului prezentat. De asemenea, utilizatorul poate specifica un scenariu de conflict prin toți parametrii sau numai prin caracteristici parțiale astfel încât poate observa modul în care se modifică mulțimea candidaților pentru centrul de gravitate în funcție de datele de intrare, identificându-le în acest mod ponderea în stabilirea rezultatului final. De asemenea, este foarte probabil ca centrul de greutate care apare de cele mai multe ori candidat cu variația caracteristicilor scenariului conflictului militar să fie centrul de gravitate strategic.

Principii de Proiectare a Agentului "Disciple-RKF"

Primul principiu de proiectare arhitecturală încearcă să determine raportul optim dintre generalitate și putere, fiind ilustrat de arhitectura agentului instructibil "Disciple-RKF" prezentată în Figura 2.

Principiul de proiectare 1 (raportul generalitate-putere): *Structurați arhitectura în module independente de domeniu care reprezintă mediul de învățare reutilizabil pentru agentul instructibil (ceea ce asigură generalitatea) și în module specifice unui domeniu (care sunt necesare a fi construite pentru un anumit agent instructibil, pentru a asigura eficiența și adaptabilitatea la domeniu).*

Al doilea principiu de proiectare ilustrat de arhitectura agentului instructibil "Disciple-RKF" este mai mult respectat de sistemele expert care implementează arhitecturi cognitive.

Principiul 2 (separarea funcțiilor cognitive): *Structurați arhitectura în module separate, fiecare orientat spre o funcție cognitivă cum sunt comunicarea, rezolvarea de probleme, învățarea și memorarea.*

În sfârșit, al treilea principiu de proiectare ilustrat de Disciple-RKF este :

Principiul 3 (modul cognitiv implementat ca agent colaborativ): *Implementați fiecare modul cognitiv ca un agent colaborativ, într-un cadru bazat pe principiul inițiativei mixte.*

Arhitectura Agentului “Disciple-RKF”

Instrumentele existente pentru construirea agenților instruitabili își schimbă obiectivul principal de la putere (adică asistența pe care o oferă dezvoltatorului) la generalitate (adică domeniul de aplicabilitate), acoperind un spectru mai larg. La capătul referitor la putere al spectrului sunt instrumentele personalizate pentru metoda rezolvării de probleme și un domeniu specific (cum ar fi SALT cu metoda sa de implementare propune-și-revizuiește – Marcus și McDermott – 1989). La capătul referitor la generalitate al spectrului sunt instrumente aplicabile unei game largi de sarcini și domenii cum ar fi SOAR (Jones, 1999) și CLIPS (Giarrantano și Riley, 1994). Între aceste capete sunt instrumentele care sunt specifice unei metode și sunt independente de domeniu (Chandrasekaran și Johnson, 1993).

Disciple-RKF este un mediu de învățare pentru agenți instruitabili (Tecuci, 1998).

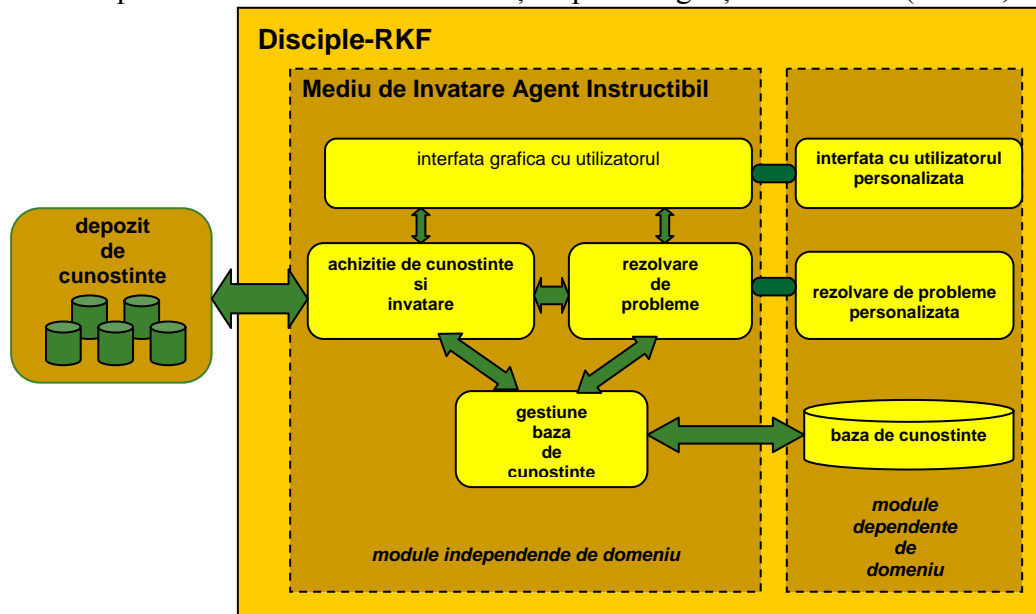


Figura 2

Componentele sale principale sunt prezentate în partea stângă a figurii 2:

- o componentă de rezolvare de probleme bazată pe reducerea sarcinilor. Aceasta include un agent de modelare care ajută utilizatorul să îmbunătățească contribuțiile sale la procesul de rezolvare a problemei, un agent de rezolvare de probleme bazat pe inițiativa mixtă (pas-cu-pas) și un agent de rezolvare de probleme autonom.
- o componentă pentru achiziția și rafinarea cunoștințelor agentului, oferind o gamă largă de operații, de la importarea de ontologii și definiții ale utilizatorului pentru elementele bazei de cunoștințe (prin intermediul editoarelor și al browserelor) până la învățarea de ontologii și învățarea de reguli.
- o componentă de gestiune pentru baza de cunoștințe care controlează accesul și actualizările la nivelul bazei de cunoștințe. Fiecare modul al Disciple-RKF poate accesa baza de cunoștințe numai prin funcțiile oferite de componenta de gestiune pentru baza de cunoștințe.
- o interfață grafică cu utilizatorul bazată pe ferestre și independentă de domeniu.

Cele trei componente din partea dreaptă a figurii 2 sunt specifice domeniului și sunt dezvoltate în momentul în care se personalizează Disciple-RKF pentru o aplicație specifică :

- o componentă de rezolvare de probleme personalizată care extinde componenta de rezolvare de probleme bazată pe reducerea sarcinilor astfel încât să satisfacă cerințele specifice rezolvării de probleme în domeniul de aplicație.
- o componentă de interfață grafică cu utilizatorul personalizată care este construită pentru agentul instructibil specific Disciple-RKF astfel încât să permită expertului în domeniu și utilizatorilor să comunice cu agentul cât mai ușor posibil (așa cum sunt obișnuiți să comunice în general).
- baza de cunoștințe a agentului Disciple-RKF.

3 PROGRAMUL CARE IMPLEMENTEAZĂ SISTEMUL EXPERT

Generalități

Agentul “Disciple-RKF/COG” a fost dezvoltat folosindu-se mediul de învățare al agentului instructibil “Disciple-RKF”, așa cum urmează să se descrie în acest capitol. Disciple-RKF constă într-un set integrat de achiziții de cunoștințe, de învățare și de module pentru rezolvare de probleme pentru o bază de cunoștințe generală având două componente principale : o ontologie de obiecte care definește termeni dintr-un domeniu de aplicație specific și un set de reguli de reduceri de sarcini exprimate cu ajutorul acestor termeni. Disciple-RKF reprezintă o evoluție semnificativă comparativ cu celelate medii Disciple deoarece implementează o reprezentare a cunoștințelor mai puternică precum și mecanisme de raționament evolute, dispunând de o interfață care facilitează raționamentul bazat pe inițiativa mixtă. Chiar mai semnificativ, Disciple-RKF încorporează module noi care permit expertului în domeniu să realizeze sarcini suplimentare de inginerie a cunoștințelor cum ar fi specificarea scenariului, modelarea procesului de rezolvare a problemei și formalizarea sarcinilor..

În general, procesul dezvoltării unui anumit agent instructibil bazat pe cunoștințe utilizând Disciple-RKF constă în două etape principale : 1) dezvoltarea unei ontologii de obiecte de către inginerul de cunoștințe și de către expertul în domeniu și 2) pregătirea agentului instructibil de către expertul în domeniu.

În prima etapă de dezvoltare, un inginer de cunoștințe lucrează împreună cu un expert în domeniu pentru a specifica tipurile de probleme care urmează să fie dezvoltate utilizând agentul instructibil “Disciple”, pentru a clarifica modul în care aceste probleme pot fi rezolvate folosind paradigma reducerii sarcinilor implementată de agentul instructibil “Disciple” și pentru a dezvolta o ontologie de obiecte.

Ontologia de obiecte constă într-o descriere ierarhică de obiecte și de caracteristici la fel ca în modelul “Protocolului de conectivitate a bazelor de cunoștințe deschise” (Chaudhri, 1998).

Proiectarea atentă și dezvoltarea ontologiei de obiecte are cea mai mare importanță deoarece este utilizată de agentul instructibil “Disciple-RKF” ca propria ierarhie generalizată pentru învățare. “Disciple-RKF” include un set de module pentru ontologie cum ar fi navigatoare și vizualizatoare bazate pe grafuri sau pe arbori (care permit o navigare ușoară și intuitivă prin ontologie) precum și editoare (folosite pentru a dezvolta și pentru a menține ontologia).

O nouă caracteristică pentru “Disciple-RKF” este posibilitatea de a defini programe de extragere a informațiilor pentru obiecte și caracteristici. Aceste programe ghidează expertul în domeniu pentru a defini instanțele care apar într-un scenariu (cum sunt de exemplu Okinawa_1945 sau Împăratul Hirohito). Figura 3 prezintă trei programe de extragere a informațiilor împreună cu un obiect “scenariu”.

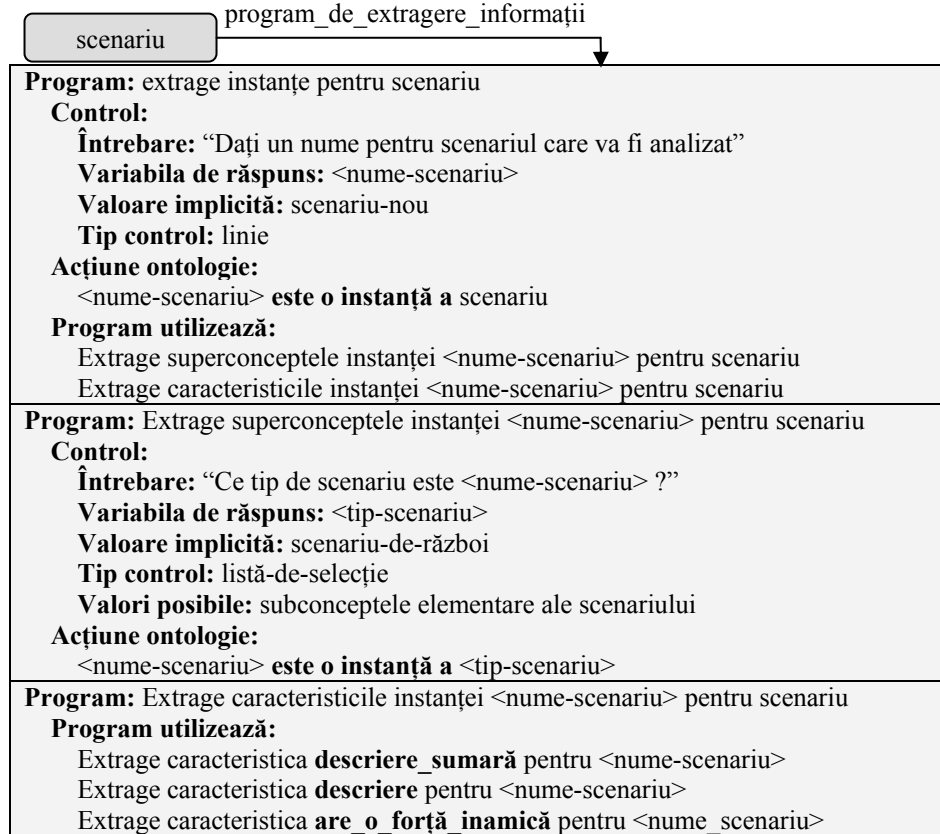


Figura 3

Primul program specifică întrebarea care trebuie să fie pusă de către “Disciple-RKF” pentru a extrage numele scenariului, modul în care răspunsul utilizatorului ar trebui să fie folosit pentru a actualiza ontologia și chiar și apariția interfeței. Utilizarea programelor de extragere a informațiilor permite unui inginer de cunoștințe să construiască rapid interfețe pentru agenții instructibili “Disciple-RKF” transformând această sarcină de dezvoltare de software într-o sarcină legată de ingineria de cunoștințe.

Rezultatul primei etape de dezvoltare o reprezintă un agent instructibil personalizat pentru un anumit domeniu de aplicație. În a doua etapă principală de dezvoltare a agentului, agentul este pregătit să rezolve probleme de către un expert în domeniu, cu asistență limitată din partea unui inginer de cunoștințe. Procesul de pregătire porneste de la o bază de cunoștințe care conține o ontologie de obiecte generale (nu și instanțe, sarcini de rezolvare de probleme sau reguli de reducere a sarcinilor) și se încheie cu o bază de cunoștințe care încorporează cunoștințele expertului pentru rezolvarea problemelor.

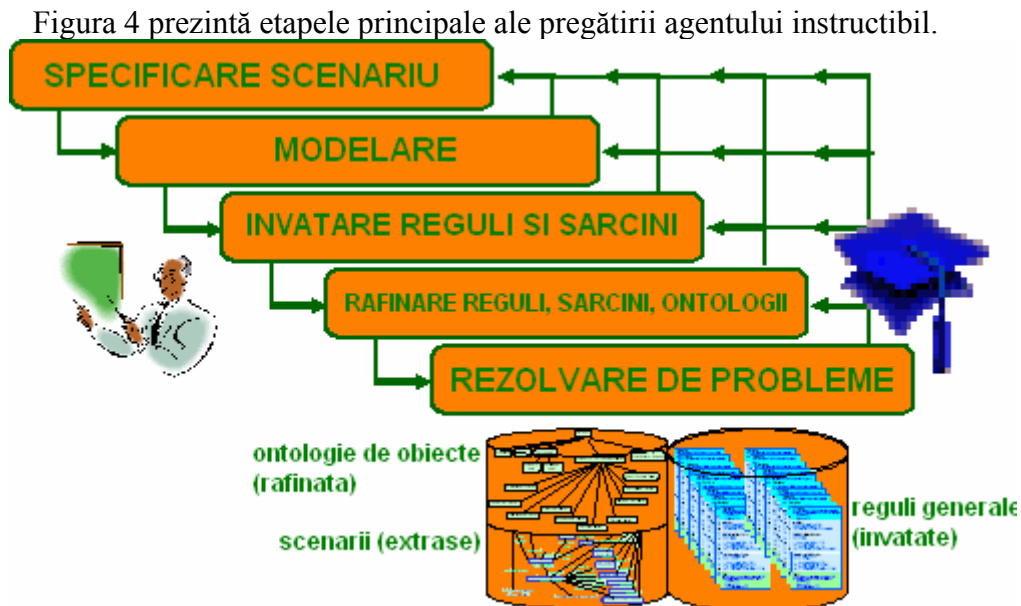


Figura 4

În timpul etapei specificare scenariu, modului de specificare a scenariului (care este un modul nou pentru “Disciple-RKF/COG”) ghidează expertul în descrierea obiectelor care definesc un anumit scenariu strategic (exemplu: invazia Statelor Unite în insula Okinawa în 1945). Expertul în domeniu nu lucrează direct cu ontologia de obiecte pentru a specifica scenariul ci are loc interacțiunea expert în domeniu-agent instructibil care este ghidată de programele de extragere de informații. Rezultatele experimentale au arătat că această sarcină poate fi realizată cu ușurință de către expertul în domeniu.

După ce expertul a specificat scenariul Okinawa_1945 (de exemplu), el poate începe modelarea pentru raționamentul în problema centrului de gravitate pentru acest scenariu particular ca o secvență de pași ce constau în reducere de sarcini. Expertul și prezintă raționamentul în limba engleză, ca și cum ar gândi cu voce tare în timp ce ar rezolva problema. Întâi, expertul în domeniu formulează sarcina de rezolvare a problemei care are nivelul cel mai mare de generalitate. Pentru a realiza această sarcină, expertul își pune o serie de întrebări. Răspunsul la fiecare din întrebări permit expertului să reducă sarcina curentă la o sarcină mai simplă. Acest proces continuă până când expertul are suficiente informații pentru a identifica un candidat pentru un centru de gravitate strategic

În etapa de învățare sarcini și reguli, “Disciple-RKF/COG” învață sarcini generale și reguli generale din pașii de reducere a sarcinilor definiți în etapa de modelare. Pasul de reducere a sarcinii constă într-o sarcină, o întrebare, un răspuns și o subsarcină. Deoarece toate aceste expresii sunt exprimate în limbaj natural, expertul în domeniu și agentul instructibil colaborează pentru a le transforma în expresii formale logice. Întâi, expresia în limbaj natural pentru fiecare sarcină este structurată într-o frază abstractă denumită numele sarcinii care nu conține nici o instanță sau constantă și câteva fraze specifice reprezentând caracteristicile sarcinii. Formalizarea este propusă de către agentul instructibil și poate fi modificată de către expertul în domeniu. Apoi, expertul în domeniu și agentul instructibil colaborează pentru a formaliza de asemenea întrebarea și răspunsul într-o explicație. Această explicație reprezintă cea mai bună aproximație al înțelesului perechii întrebare-răspuns care poate fi formulată cu termeni din ontologia de obiecte.

În esență, agentul instructibil va utiliza un raționament și o ghidare asemănătoare pentru a propune un set de părți de explicații plauzibile din care expertul le va selecta pe cele mai plauzibile (Tecuci, 2001).

Bazându-se pe formalizările obținute și pe ontologia de obiecte, agentul instructibil învață sarcina generală și regula generală. Atât sarcina cât și regula au o structură neformală care menține limbajul natural al expertului fiind utilizat în comunicația agent instructibil – expert în domeniu dar și o structură formală care este utilizată în modul de raționament al agentului instructibil.

Inițial, când agentul instructibil nu are nici sarcini și nici reguli, expertul în domeniu învață agentul instructibil cum să rezolve probleme și Disciple-RKF/COG generează sarcinile și regulile parțial învățate, așa cum s-a prezentat mai sus. Deoarece agentul instructibil învață de la expertul în domeniu, interacțiunea dintre cele două entități evoluează de la o relație de tip profesor-student la o relație în care cele două entități colaborează pentru rezolvarea problemei. Pe parcursul etapei de rezolvare a problemei folosind paradigma inițiativei mixte, Disciple-RKF/COG învață nu numai din contribuțiile pe care le primește de la expert, dar și din încercările sale de a rezolva probleme finalizate cu succes sau cu insucces.

Regula formală învățată include două condiții de aplicabilitate, o condiție plauzibilă la limita superioară și o condiție plauzibilă la limita inferioară. Condiția plauzibilă la limita superioară rezultă din generalizarea maximală a exemplului primit și din explicația corespunzătoare. Această condiție permite regulii să fie aplicabilă în multe situații în mod analog, însă rezultatul se poate să nu fie corect. Pe de altă parte, condiția plauzibilă la limita inferioară rezultă din generalizarea minimală a exemplului primit și din explicația corespunzătoare. Această condiție permite regulii să fie aplicabilă numai în situații care sunt foarte asemănătoare cu cea din care regula a fost învățată. De aceea, raționamentul corespunzător este mult mai probabil să fie corect decât cel corespunzător condiției plauzibile la limita superioară. Agentul instructibil va aplica regula învățată pentru a rezolva noi probleme, iar răspunsul primit din partea expertului în domeniu va fi utilizat pentru a rafina mai departe regula. În esență, cele două condiții vor converge una spre cealaltă (de obicei, prin specializarea condiției plauzibile la limita superioară și prin generalizarea condiției plauzibile la limita inferioară), amândouă apropiindu-se de condiția exactă de aplicare a regulii. Rafinarea regulii poate conduce la o sarcină complexă de reducere a regulilor, cu condiții adiționale “cu excepția cazului în care” care trebuie să nu fie satisfăcute pentru ca regula să fie aplicabilă. Sarcinile sunt rafinate într-un mod asemănător (Boicu, 2000).

Este important de subliniat faptul că expertul în domeniu nu se confruntă direct cu sarcinile învățate sau cu regulile învățate, ci numai cu exemplele lor utilizate în rezolvarea de probleme. De aceea, operațiile complexe ce țin de ingineria de cunoștințe de a defini și de a găsi erorile regulilor de rezolvare a problemelor sunt înlocuite în abordarea “Disciple-RKF/COG” cu operații mai simple de a defini și de a analiza exemple specifice.

După ce agentul instructibil a fost pregătit, el poate fi folosit în modul autonom de rezolvare de probleme, pentru a identifica și pentru a testa candidații pentru centre de gravitate strategice pentru un scenariu nou.

Reprezentarea Cunoștințelor ce Pot Fi Învățate

Baza de cunoștințe a “Disciple-RKF/COG” este structurată într-o ontologie de obiecte și un set de reguli de reduceri a sarcinilor și de construire a soluției. Ontologia de obiecte este o reprezentare ierarhică a obiectelor din domeniul de aplicație. Aceasta reprezintă diferite tipuri de obiecte, proprietățile pentru fiecare obiect precum și relațiile care există între obiecte. Ontologia de obiecte pentru “Disciple-RKF” pentru problema centrului de gravitate conține 355 de concepte de obiecte. Mai mult, un scenariu precum Sicilia_1943 utilizat în acest referat este descris cu ajutorul a aproximativ 900 de fapte (triple de forma “obiect caracteristică valoare”). Un fragment din ontologia de obiecte pentru problema centrului de gravitate este prezentat în Figura 5.

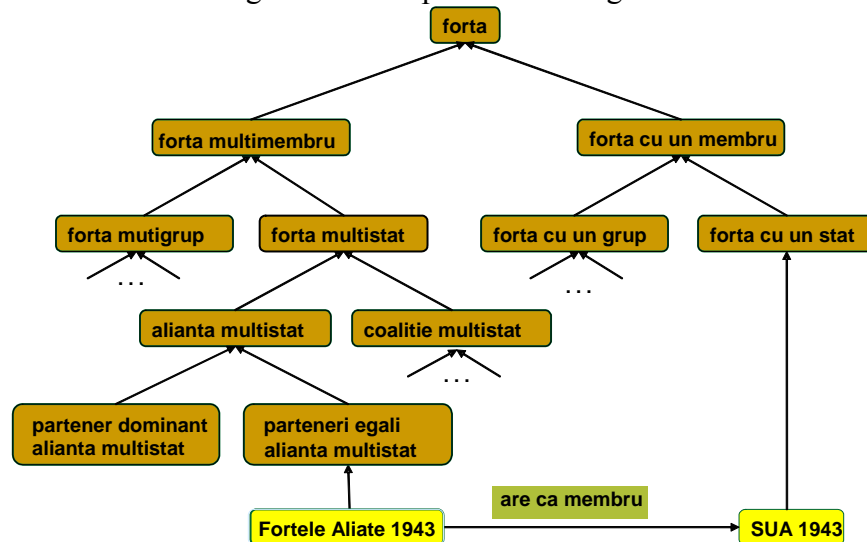


Figura 5

Ontologia de obiecte este incompletă. Există concepte și instanțe relevante din domeniul de aplicație care nu sunt reprezentate. Mai mult, reprezentarea unui concept dat sau instanță poate fi incomplet în acest sens de a nu include toate proprietățile sau relațiile sale relevante. Ontologia de obiecte va fi extinsă de către agentul instructibil în timpul procesului de învățare și de rezolvare de probleme (Boicu, 2003).

În plus față de ierarhia instanțelor și conceptelor ilustrate în Figura 5, ontologia de obiecte include de asemenea o ierarhie de caracteristici. În această ierarhie, spre exemplu, caracteristica “are_ca_sef_al_guvernului” este o subcaracteristică a caracteristicii “are_ca_lider_politic”, care este o subcaracteristică a caracteristicii “are_ca_lider_de_control”. Fiecare caracteristică C este reprezentată de un domeniu și de un interval. Domeniul lui C este un concept care reprezintă toate obiectele care pot avea caracteristica C. Intervalul lui C este un concept care reprezintă toate valorile posibile ale lui C. Ierarhia de caracteristici pentru centrul de gravitate conține 193 de definiții de caracteristici.

Ontologia de obiecte are un rol crucial în “Disciple-RKF/COG”, reprezentând baza reprezentării cunoștințelor, comunicației utilizator-agent instructibil, rezolvării de probleme, achiziției de cunoștințe și învățării. Utilizând conceptele (obiectelor și caracteristicilor) din ontologia de obiecte, se pot defini concepte mai complexe cum ar fi expresii logice implicând aceste concepte. Unitatea de reprezentare de bază pentru un asemenea concept are forma $\{?O_1, ?O_2, \dots, ?O_n\}$, unde fiecare $?O_i$ are structura indicată în exemplul de mai jos.

În exemplul de mai jos, concept_i este un concept al obiectului din ontologia de obiecte, un interval numeric, sau o listă de șiruri de caractere, iar ?O₁,...,?O_{im} sunt variabile distincte din mulțimea {?O₁,?O₂,...,?O_n}.

Exemplu 1

?O _i este	concept _i
caracteristica _{i1}	?O _{i1}
...	
caracteristica _{in}	?O _{in}

De exemplu, conceptul “perechea de entități ?O₁ și ?O₂, unde ?O₁ este un partener ega, alianță multistat care are, unul dintre membrii săi pe ?O₂ care este un stat cu o forță” este reprezentată de exemplul de mai jos.

Exemplu 2

?O ₁ este	partener_egal_alianta_multistat
are_ca_membru	?O ₂
?O ₂ este	forță_cu_un_stat

În general, un concept poate fi o expresie conjunctivă de forma
 $URB \ \& \ \sim UR_{B_1} \ \& \ \dots \ \& \ \sim UR_{B_p}$
 (unde URB=unitatea de bază de reprezentare)
 semnificând că orice instanță a conceptului care satisface unitatea de reprezentare de bază nu satisface unitatea de reprezentare de bază₁ și ... și nu satisface unitatea de reprezentare de bază_p.

Totuși, în loc de “~” (operatorul “not”) putem scrie “cu excepția cazului în care” așa se prezintă mai jos.

Exemplu 3

?O ₁ este	partener_egal_alianta_multistat
are_ca_membru	?O ₂
?O ₂ este	forță_cu_un_stat
cu excepția cazului în care	
?O ₂ este	forță_cu_un_stat
are_o_contribuție_militară	?O ₃
?O ₃ este	contribuție_militară_minoră

Acest concept reprezintă “perechea de entități ?O₁ și ?O₂, unde ?O₁ este un partener egal în alianța multistat care are, ca unul din membrii săi, pe ?O₂, care este o forță cu un stat, cu excepția cazului în care ?O₂ este o forță cu un stat cu o contribuție militară minoră”.

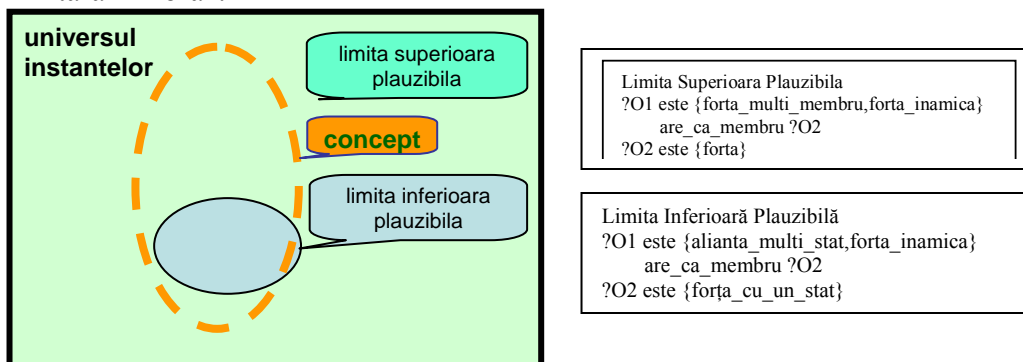


Figura 6

Ontologia de obiecte stă la baza generalizării limbajului pentru învățare. De exemplu, în al doilea caz, conceptul poate fi generalizat înlocuind un obiect din descrierea sa (“partener_egal_alianță_multistat”) cu un concept mai general din ontologie (“alianță_multi_stat”). Alte reguli de generalizare sau specializare pot fi folosite pentru a generaliza sau specializa astfel de concepte ca, de exemplu, eliminarea sau inserarea unei caracteristici a unui obiect sau a unei condiții “cu excepția cazului în care”, generalizând un număr la un interval sau un interval la un interval mai mare (Tecuci, 1998).

Conceptele învățate parțial sunt reprezentate ca spații de versiuni plauzibile (Tecuci, 1998) așa cum este prezentat în Figura 6.

Exemplu 4

?O ₁ este	forță_multimembru
are_ca_membru	?O ₂
?O ₂ este	forță
și	
?O ₂ este	forță_inamică
are_o_contribuție_militară	?O ₂
?O ₃ este	forță

Limita superioară plauzibilă a acestui spațiu de versiuni plauzibile conține cele două concepte prezentate în exemplul 4. Similar, limita inferioară plauzibilă a acestui spațiu de versiuni conține două concepte, unul în care ?O₁ este alianță_multi_stat, și unul în care ?O₁ este forță_inamica. În versiunea curentă pentru “Disciple-RKF/COG”, aceleași caracteristici apar atât în limita superioară cât și în limita inferioară (ca de exemplu “are_ca_membru” în Figura 6).

Conceptul E_h care trebuie să fie învățat (conceptul reprezentat în Figura 6) este o aproximare, mai puțin general decât unul din conceptele din limita superioară plauzibilă. E_h este, de asemenea, din nou o aproximare, mult mai generală decât oricare din conceptele din limita inferioară plauzibilă. În timpul învățării, cele două limite converg una către cealaltă prin generalizări și specializări succesive, aproximându-l pe E_h din ce în ce mai bine. Această teorie este diferită de cea a versiunilor de spații introdusă de Mitchell în 1978, în care unul dintre conceptele din limita superioară este întotdeauna mai general decât conceptul care se vrea învățat (și limita superioară este întotdeauna specializată în timpul învățării) și oricare din conceptele din limita inferioară este întotdeauna mai puțin general decât conceptul care se vrea învățat (și limita inferioară este întotdeauna generalizată în timpul învățării). Diferența majoră este aceea că versiunile de spații introduse de Mitchell în 1978 sunt bazate pe o reprezentare completă a spațiilor care includ conceptul care se dorește învățat. Dimpotrivă, reprezentarea spațiului pentru “Disciple-RKF/COG” este bazată pe o ontologie de obiecte incompletă dar în evoluție, așa cum s-a precizat mai sus. De aceea, “Disciple-RKF/COG” abordează probleme de învățare mult mai complexe și mult mai reale în contextul unui spațiu de reprezentare în evoluție.

Noțiunea de spațiu de versiuni plauzibile este funcamenta pentru reprezentarea cunoștințelor, rezolvarea de probleme și învățarea de metode de către “Disciple-RKF/COG”. Toate elementele de informație din baza de cunoștințe sunt reprezentate folosind această construcție și sunt învățate sau rafinate de către agentul instructibil. De exemplu, “Disciple-RKF/COG” învață definiții de caracteristici generale din exemple specifice, domeniile și intervalele ale caracteristicilor învățate parțial fiind reprezentate ca spații de versiuni plauzibile.

Baza de cunoștințe pentru Disciple-RKF/COG conține de asemenea reguli de reducere a sarcinilor și reguli de construcție a soluțiilor care sunt învățate din exemple specifice de reduceri sau construcții. Spre exemplu, regula este o structură IF-THEN care exprimă în ce condiții un anumit tip de sarcină poate fi redus la o subsarcină mai simplă (sau la mai multe subsarcini, în cazul altor reguli). Regula este interpretată după cum urmează : dacă sarcina de rezolvat este T_1 , punem întrebarea Q și dacă răspunsul este A (sau, echivalent, dacă aplicabilitatea condiției regulii este satisfăcută), atunci putem reduce pe T_1 la T_{11} (o subsarcină mai simplă pentru T_1).

Regula de mai sus este una foarte simplă, cu o singură condiție principală. În general, totuși, în plus față de condiția principală, o regulă învățată poate să aibă mai multe condiții de tipul “cu excepția cazului în care” (care ar trebui să nu fie satisfăcute pentru ca regula să fie aplicabilă), la fel ca și excepții pozitive sau negative. De aceea, în general, condiția regulii este un concept din “URB cu excepția cazului în care $URB_1 \dots$ cu excepția cazului în care URB_p ” însemnând că regula poate fi aplicată pentru orice instanță a conceptului condiție. Regula de mai sus este doar parțial învățată. De aceea, în locul unei condiții aplicabilă singular, are un spațiu de versiuni plauzibile pentru condiția exactă care trebuie să fie învățată”. Baza de cunoștințe pentru Disciple-RKF/COG are 368 de reguli de reducere, toate învățate de către agent. De asemenea, conține 269 de reguli de construcție.

Principii de proiectare

Principiul de proiectare 4 (structurarea bazei de cunoștințe): *Structurați baza de cunoștințe în cea mai generală și reutilizabilă componentă a sa (ontologia de obiecte) și în cea mai specifică componentă a sa (metodele de raționament sau regulile).*

Principiul de proiectare 5 (informațiile învățate parțial): *Proiectați agentul instructibil pentru a permite reprezentarea, utilizarea și rafinarea informațiilor învățate parțial.*

Modelarea, Învățarea și Rezolvarea de Probleme Bazate pe Inițiativa Mixtă

Abordarea “Disciple-RKF/COG” acoperă toate etapele dezvoltării și utilizării sistemului expert. Inițial, un inginer de cunoștințe lucrează împreună cu un expert în domeniu pentru a dezvolta o ontologie pentru domeniul de aplicație. Ei utilizează modulul de importare a ontologiei (pentru a extrage elemente relevante ale ontologiei din depozite de cunoștințe existente) la fel ca și diverse editoare și navigatoare de ontologii ale “Disciple-RKF/COG”. Rezultatul acestei dezvoltări a bazei de cunoștințe o reprezintă ontologie de obiecte prezentată în figura 5 care este suficient de completă pentru a fi folosită ca o ierarhie generalizată pentru învățare, permițându-i expertului în domeniu să învețe agentul instructibil cum să rezolve probleme cu asistență limitată din partea inginerului de cunoștințe. Procesul de învățare este ilustrat în Figura 7 și urmează să fie discutat mai jos.

Învățarea Regulilor

Expertul în domeniu formulează o sarcină inițială de rezolvare de problemă cum ar fi “Determinați centrul de gravitate pentru scenariul Sicily_1943” (Figura 7) și arată agentului instructibil modul în care să rezolve această sarcină folosind paradigma reducerii sarcinilor. Expertul în domeniu utilizează limbajul natural, ca și cum ar gândi cu voce tare. Expertul în domeniu pune întrebări legate de anumite informații care sunt relevante pentru rezolvarea sarcinii curente. Răspunsul identifică informațiile și conduce expertul la reducerea sarcinii curente la o sarcină mai simplă (sau, în alte cazuri la mai multe sarcini mai simple). Figura 7 prezintă o secvență de pași de reducere de sarcini.

Tabelul 1 și Tabelul 2 prezintă problema învățării de reguli și metoda Disciple-RKF/COG. Acestea vor fi ilustrate în cele ce urmează.

Să considerăm pasul 4 din arborele de reducere a sarcinilor prezentat în figura 7. Din acest pas de reducere a sarcinii, Disciple-RKF/COG a învățat regula reducerii de sarcini.

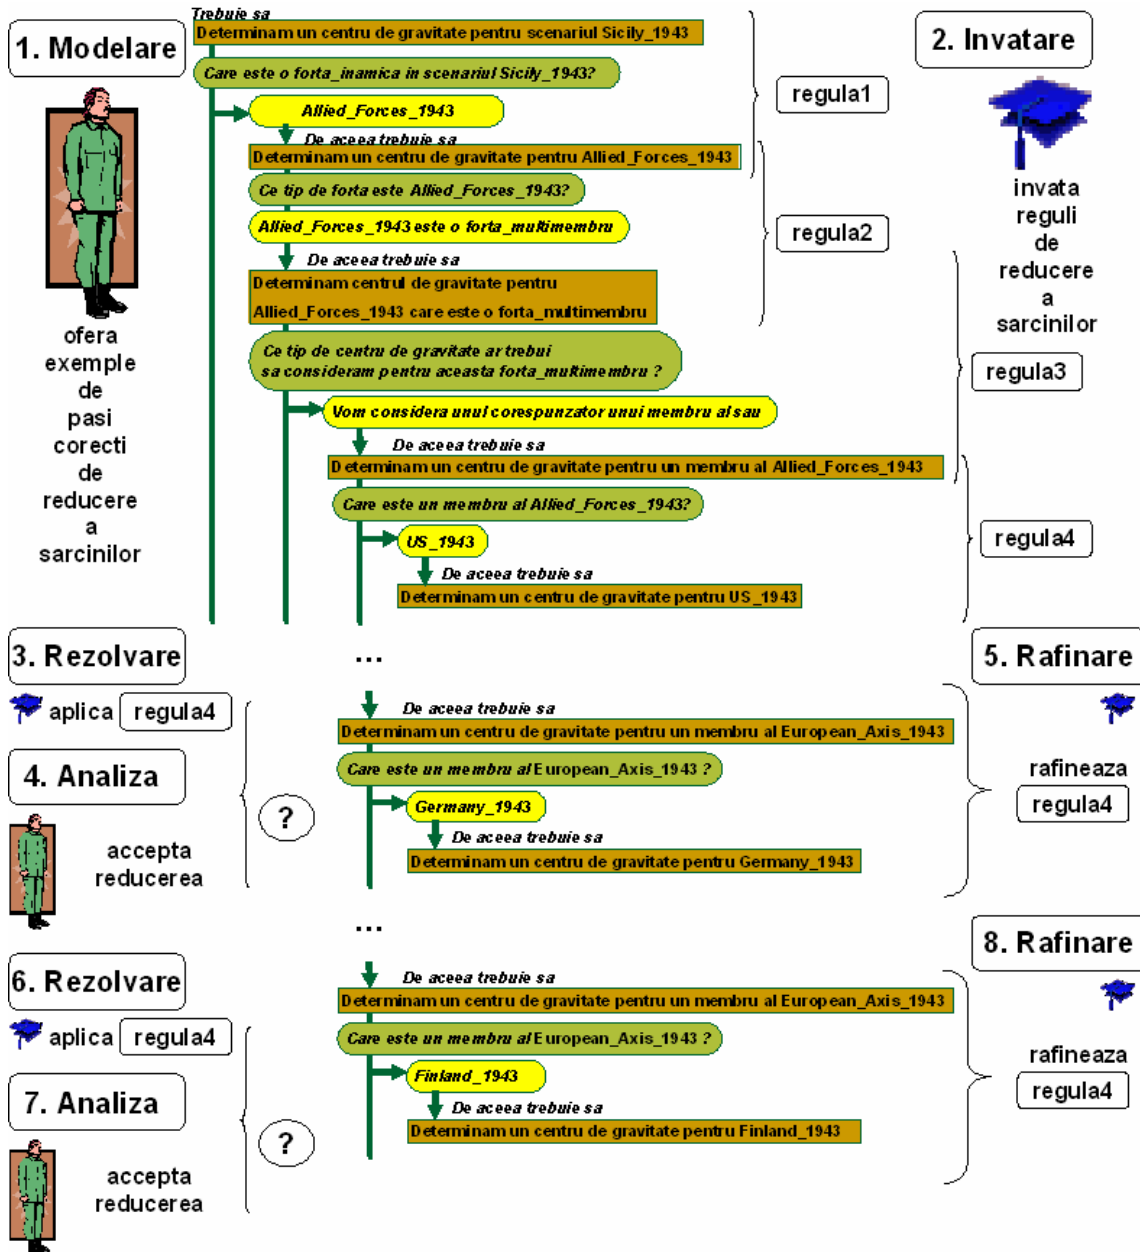


Figura 7

Învățarea de reguli este un proces bazat pe inițiativa mixtă dintre expert (care știe de ce reducerea este corectă și poate ajuta agentul instructibil să înțeleagă acest lucru) și agentul "Disciple-RKF/COG" (care este capabil să generalizeze exemplul reducerii de sarcini și explicația expertului în domeniu la o regulă generală utilizând ontologia de obiecte ca un limbaj de generalizare).

Tabelul 1: Problema învățării de reguli

<p>SE DĂ :</p> <ul style="list-style-type: none">• un exemplu de pas de reducere de sarcină• o bază de cunoștințe care include o ontologie de obiecte și un set de reguli de reduceri de sarcini• un expert în domeniu care înțelege de ce exemplul este corect și poate răspunde întrebărilor agentului instructibil <p>SE CERE :</p> <ul style="list-style-type: none">• un spațiu de versiuni plauzibile pentru reguli de reducere a sarcinilor care este generalizarea unui pas de reducere de sarcini specific.• o ontologie de obiecte extinsă (dacă este necesară pentru învățarea de reguli).
--

Tabelul 2: Metoda învățării de reguli

<p>1. Generarea Explicației</p> <p>Se identifică o explicație formală EX care să arate de ce exemplul E este corect folosind o interacție bazată pe inițiativa mixtă împreună cu expertul în domeniu. Explicația este o aproximație a sensului întrebării și a răspunsului, exprimate cu obiectele și proprietățile din ontologia de obiecte. Pe parcursul procesului de generare a explicației, noi obiecte și noi proprietăți pot fi obținute de la expertul în domeniu și adăugate la ontologia de obiecte.</p> <p>2. Generarea Variabilei</p> <p>Se generează o variabilă pentru fiecare instanță, număr sau șir de caractere care apare în exemplu ca și explicația lui. Apoi se utilizează aceste variabile, exemplul și explicația pentru a crea o instanță I a conceptului reprezentând condiția de aplicabilitate a regulii care se vrea a fi învățată. Acesta este conceptul care va fi învățat ca o parte a învățării de reguli</p> <p>3. Generarea Regulii</p> <p>Se generează sarcinile, întrebarea și răspunsul regulii înlocuind fiecare instanță sau constantă din exemplul E cu variabila corespunzătoare generată în pasul 2. Se generează apoi spațiul de versiuni plauzibile al aplicabilității condiției regulii. Conceptul reprezentat de această condiție este un set de instanțe și constante care produc instanțierile corecte a regulii. Limita inferioară plauzibilă pentru acest spațiu de versiuni se obține minimizând generalizarea lui I determinat în pasul 2, generalizare care nu conține nici o instanță. Limita superioară plauzibilă pentru acest spațiu de versiuni se obține maximizând generalizarea lui I determinat în pasul 2.</p> <p>4. Analiza regulii</p> <p>Dacă există orice variabilă din partea “THEN” a regulii care nu este legată la o variabilă din partea “IF” a regulii, sau dacă regula are prea multe instanțe în baza de cunoștințe, atunci se interacționează cu expertul în domeniu pentru a extinde explicația exemplului și pentru a actualiza regula dacă se găsesc noi explicații. Altfel, se încheie procesul de învățare de reguli.</p>

- Acest proces este bazat pe protocolul de comunicație care ține cont de faptul că :
- este mai ușor pentru un expert în domeniu să înțeleagă propoziții într-un limbaj formal al agentului instructibil decât este să producă astfel de propoziții formale;
 - este mai ușor pentru agentul instructibil să genereze propoziții formale decât îi este să înțeleagă propoziții în limbajul natural folosit de către expert.

Întrebarea și răspunsul ei din pasul de reducere a sarcinii reprezintă modul de raționament al expertului în domeniu (sau explicația) pentru a realiza reducerea în cauză. Deoarece acestea sunt în limbaj natural, expertul în domeniu trebuie să ajute agentul instructibil să le “înțeleagă” în termeni ai conceptelor și caracteristicilor din ontologia de obiecte. Să considerăm întrebarea și răspunsul utilizate în exemplul din Figura 7 “Care este un membru al Allied_Forces_1943 ? US_1943”. Înțelesul lor în ontologia de obiecte este “Allied_Forces_1943 au_ca_membru US_1943”. Vom considera expresia din urmă explicația exemplului.

Dacă un expert în domeniu poate înțelege sensul expresiei formale de mai sus, acesta nu poate îl defini cu ușurință pentru agent deoarece nu este un inginer de cunoștințe. De exemplu, ar avea nevoie să utilizeze limbajul formal al agentului. Dar aceasta nu ar fi suficient deoarece expertul ar trebui să știe totodată numele potențialelor mii de concepte și proprietăți din ontologia de obiecte. De aceea, agentul instructibil va face presupuneri referitor la înțelesuri plauzibile ale perechii întrebare-răspuns utilizând prelucrarea limbajului natural, analog cu raționamentul folosit la regulile învățate anterior utilizând și euristici generale, exprimându-le sub formă de fragmente de explicații. În general, un fragment de explicație identificat de agent este o relație (sau un lanț de relații) care implică instanțe, concepte și constante din pasul de reducere a sarcinii și din baza de cunoștințe. Agentul instructibil va propune apoi aceste fragmente de explicații expertului în domeniu, ordonate după plauzibilitatea lor astfel încât expertul în domeniu să le poată selecta pe cele care su semnificația perechii întrebare-răspuns. Expertul în domeniu poate de asemenea să ajute agentul instructibil să propună fragmentele de explicații corecte oferindu-i indicii, cum ar fi de exemplu evidențierea faptului că un obiect relevant ar trebui să fie o parte a explicației.

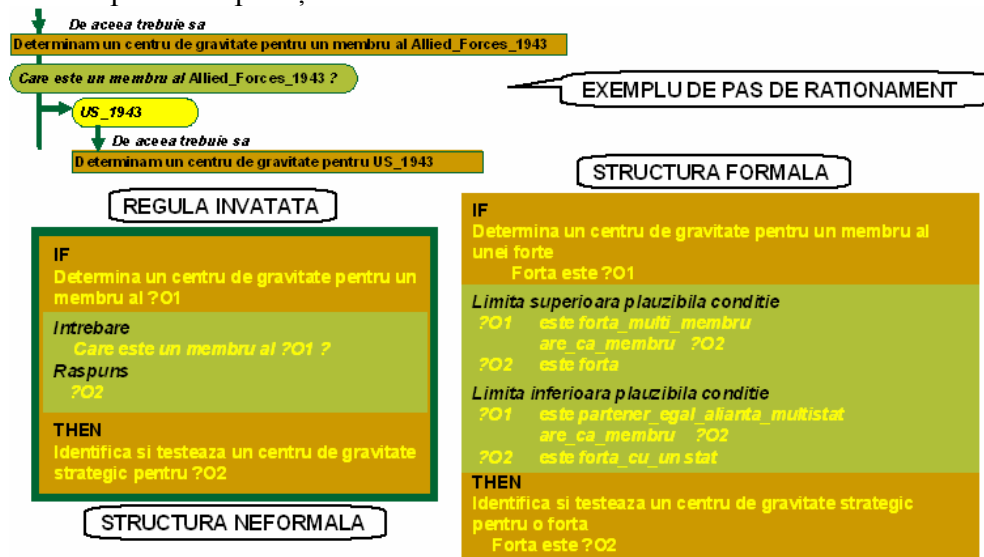


Figura 8

Utilizând exemplul și explicația sa, Disciple-RKF/COG va genera regula pentru reducerea de sarcini din partea dreaptă a Figurii 8. Mai întâi, agentul instructibil va genera o variabilă pentru fiecare instanță, număr sau șir de caractere care apare în exemplu și explicația lui. Apoi va utiliza aceste variabile V pentru a generaliza reducerea de sarcini pornind de la exemplul E într-o regula R IF-THEN înlocuind fiecare instanță sau concept cu variabila corespunzătoare.

Următorul pas în procesul de învățare de reguli îl reprezintă determinarea instanțierii variabilelor V care conduc la pașii corecți de reducere a regulilor. Așadar, trebuie să determinăm conceptul care reprezintă un set de instanțe al variabilelor V ale regulii pentru care instanțierea corespunzătoare a regulii R este corectă. Acest concept poartă numele de “condiția de aplicabilitate a regulii R ” și “Disciple-RKF/COG” îl învață utilizând abordarea spațiului de versiuni plauzibile. Deci, consideră setul tuturor condițiilor aplicabile care sunt consistente cu exemplele cunoscute și cu explicațiile lor și reduce acest set pe măsură ce noi exemple și explicații suplimentare sunt găsite. Mai mult, ca în algoritmul eliminării candidatului, spațiul versiunilor plauzibile este reprezentat de o limită inferioară plauzibilă și de o limită superioară plauzibilă.

Spațiul inițial al versiunilor plauzibile pentru regula R este determinat după cum urmează. La început se determina instanța condiției I corespunzătoare exemplului inițial:

Exemplu 4

IC: ?O ₁ este	Allied_Forces_1943
are_ca_membru	?O ₂
?O ₂ este	US_1943

De observat faptul că această condiție include proprietatea “are_ca_membru” din explicația din exemplu. Aceasta este o proprietate esențială a obiectelor și, pentru același motiv ca în cazul învățării bazate pe explicații (Mitchell, 1986, DeJong și Mooney, 1986) va reduce semnificativ numărul exemplurilor necesare pentru învățare.

Apoi se generează I în două moduri diferite pentru a genera cele două limite a spațiului de versiuni. Limita inferioară plauzibilă este setul celor mai puțin generale generalizări ale lui I care nu include nici o instanță. Cele mai puțin generale concepte din ontologia de obiecte care acopera *Allied_Forces_1943* sunt *forta_inamica* și *partener_egal_alianta_multistat*. Totuși, *Allied_Forces_1943* are proprietatea *are_ca_membru*, și, de aceea, oricare din generalizări trebuie să se găsească în domeniul acestei proprietăți, care se întâmplă să fie *forta_multimembru*. Drept consecință, setul generalizărilor minimale pentru *Allied_Forces_1943* este dată de expresia urmatoare :

$$\{forta_opusa, partener_egal_alianta_multistat\} \cap \{forta_multimembru\} = \{partener_egal_alianta_multistat\}$$

Similar (dar utilizând intervalul proprietății *are_ca_membru* care este forță), se poate determina setul generalizărilor minimale pentru *US_1943* ca $\{forta_cu_un_stat\}$.

Ca o consecință, condiția la limita inferioară plauzibilă este :

Exemplu 5

PLB: ?O ₁ este	partener_egal_alianta_multistat
are_ca_membru ?O ₂	
?O ₂ este	forta_cu_un_stat

Motivul pentru care limita inferioară nu conține nici o instanță este aceea că regula învățată va fi utilizată de “Disciple-RKF/COG” în alte scenarii (cum ar fi *Afghanistan_2001_2002*), unde instanțele din *Sicily_1943* nu există astfel încât agentul instructibil nu ar ști cum să le instanțieze. Pe de altă parte, nu se poate afirma că conceptul ce se vrea învățat este mai general decât limita inferioară, așa cum s-a argumentat anterior și s-a prezentat în Figura 6.

Utilizând o procedură asemănătoare (dar considerând cea mai generală generalizare a instanțelor și constantelor din exemplu și din explicații), Disciple-RKF/COG determină condiția la limita superioară plauzibilă și generează regula din partea dreaptă a Figurii 8 :

Exemplu 6

PUB: ?O ₁ este	forta_multimembru
are_ca_membru ?O ₂	
?O ₂ este	forta

Ultimul pas al procesului de învățare a regulii este de a analiza regula generată. De exemplu, agentul instructibil poate determina că o variabilă din partea THEN a regulii nu este legată la nici o variabilă din partea IF a regulii. Aceasta este un indicator al unei reguli care a fost învățată pe baza unei explicații incomplete, determinând agentul să reinițieze procesul de generare de explicații. Câteodată explicația lipsă este atât de evidentă expertului în domeniu încât pur și simplu o ignoră, ca în cazul următor "US_1943 are_un_guvern guvern_US_1943". Agentul instructibil va selecta automat o astfel de explicație dacă produce o legătură la o variabilă nelegată. Câteodată, chiar și când toate variabilele regulii sunt legate, numărul instanțelor regulii poate să rămână foarte mare. În acest caz, agentul va încerca să identifice ce variabile sunt cele mai puțin legate și va încerca să le constrângă și mai mult propunând fragmente de explicații suplimentare.

De observat faptul că Disciple-RKF a reușit să învețe o regulă rezonabilă din numai un singur exemplu și explicația sa, o regulă care poate fi utilizată de agentul instructibil în procesul de rezolvare al problemei. Într-adevăr, va aplica regula pentru a reduce o sarcină curentă dacă condițiile la oricare din limite este satisfăcută. Regula 4 are numai un concept în limita superioară plauzibilă, și de asemenea un singur concept în limita inferioară plauzibilă. În general, totuși, fiecare limită poate să conțină mai mult decât un singur concept, așa cum s-a discutat anterior și s-a prezentat în Figura 6. Spunem că condiția la limita inferioară plauzibilă acoperă un exemplu dacă toate conceptele alternative din această limită acoperă instanțele din exemplu. Dimpotrivă, spunem că condiția la limita superioară plauzibilă acoperă un exemplu dacă cel puțin unul din conceptele alternative din această limită acoperă exemplul.

Rafinarea Regulilor

Tabelul 3: Problema rafinării

<p>SE DĂ :</p> <ul style="list-style-type: none"> • un spatiu de versiuni plauzibile de reguli de reduceri al sarcinii R • un exemplu pozitiv sau negativ E al regulii (adică un pas de reducere al sarcinii corect sau incorect care are aceleași sarcini IF și THEN ca și R). • o bază de cunoștințe care include o ontologie de obiecte și un set de reguli de reduceri de sarcini. • un expert în domeniu care înțelege de ce pasul de reducere al sarcinii este corect sau incorect și poate răspunde întrebărilor agentului. <p>SE CERE :</p> <ul style="list-style-type: none"> • o regulă rafinată care acoperă exemplul dacă este pozitiv, sau care nu acoperă exemplul dacă este negativ. • o ontologie de obiecte extinsă (daca este necesară pentru rafinarea regulii).

Pe măsură ce Disciple-RKF/COG învață noi reguli de la expertul în domeniu, interacțiunea dintre expertul în domeniu și agentul instructibil evoluează de la o relație de tip profesor-student la o relație de colaborare pentru rezolvarea problemei. În timpul acestei faze de rezolvare a problemei folosind paradigma inițiativei mixte, agentul instructibil învață nu numai din contribuțiile pe care le primește de la expert, dar și din încercările proprii de rezolvare de probleme soldate cu succes sau cu insucces, toate conducând la rafinarea regulilor învățate. În același timp, agentul instructibil poate extinde ontologia de obiecte cu noi obiecte sau proprietăți.

Problema rafinării regulii și metodele sunt prezentate în Tabelele 3,4 și 5. Rezultatul procesului de învățare al regulii descris în Tabelul 2 și ilustrat mai sus este o regulă cu o condiție principală de spațiu de versiuni plauzibile. Pe parcursul procesului de rafinare a regulilor, regula poate acumula mai multe condiții de tipul “cu excepția cazului în care”. Din această cauză tabelele 3 și 4 presupun că regula R, pentru a fi rafinată pe baza exemplului E are atât o condiție principală învățată parțial cât și o condiție de tipul “cu excepția cazului în care” parțial învățată. Aceste metode sunt extinse natural când există astfel de condiții. Noul exemplu al regulii (pozitiv sau negativ) precum și condiția regulii pot să fie situate în regiuni relevante, așa cum se va prezenta în cele ce urmează. Modul în care regula este rafinată depinde de tipul exemplului și de regiunea în care este situat, așa cum este descris în tabelele 3 și 4. În cele ce urmează sunt prezentate aceste metode.

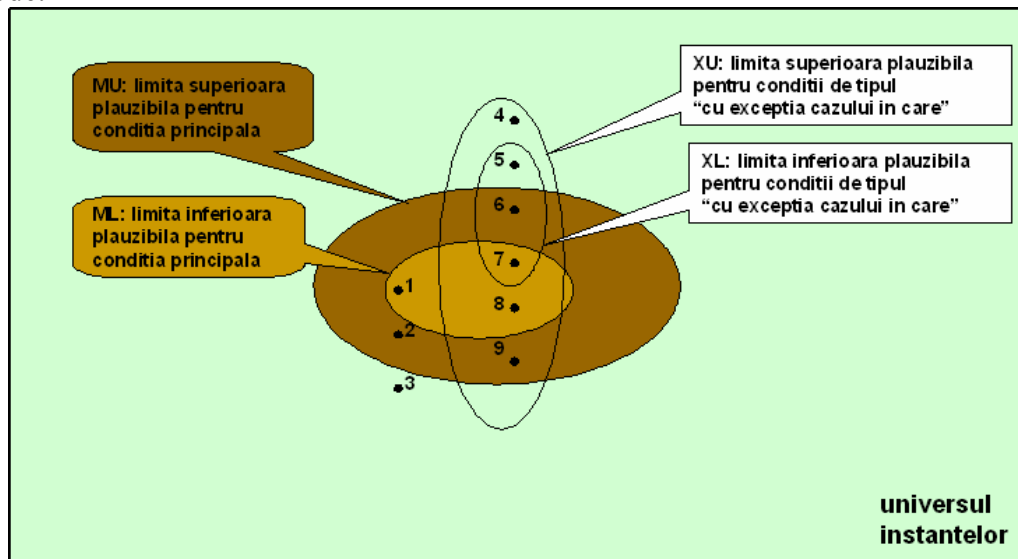


Figura 9

Așa cum este indicat în Figura 7, Disciple-RKF/COG a aplicat regula 4 pentru a reduce sarcina “determină centrul de gravitate pentru un membru al European_Axis_1943”, generând un exemplu care este acoperit de condiția regulii la limita superioară plauzibilă. Această reducere a fost acceptată de către expertul în domeniu ca fiind corectă. De aceea, agentul instructibil a generalizat condiția la limita inferioară plauzibilă pentru a o acoperi. Spre exemplu, European_Axis_1943 este o forță multimembru dar nu este un partener egal alianță multistat. Este un partener dominant alianță multistat dominată de Germany_1943. Ca o consecință, Disciple-RKF/COG generalizează automat condiția regulii la limita inferioară plauzibilă pentru a acoperi acest exemplu.

Tabelul 4: Rafinarea regulii cu un exemplu pozitiv

1. Dacă exemplul pozitiv E este acoperit de ML și nu este acoperit de XU (cazul 1, Figura 9), atunci nu este necesar să rafinăm regula pentru că exemplul este clasificat corect ca pozitiv de regula corectă.
2. Dacă E este acoperit de MU, dar nu este acoperit de ML și XU (cazul 2, Figura 9), atunci generalizează minim pe ML pentru a acoperi E și pentru a rămâne mai puțin general decât MU. Eliminați de asemenea din MU elementele care nu acoperă E.
3. Dacă E nu este acoperit de MU (cazurile 3,4 și 5 în Figura 9) sau dacă E este acoperit de XL (cazurile 5,6 și 7 în Figura 9) atunci păstrează E ca o excepție pozitivă a regulii.
4. Dacă E este acoperit de ML și XU, dar nu este acoperit de XL (cazul 8 în Figura 9), atunci interacționează cu expertul pentru a găsi o explicație de forma "Pasul de reducere al sarcinii este corect deoarece I_i este C_i " unde C_i este un concept din ontologie. Dacă o astfel de explicație este găsită atunci XU este minimal specializat să nu mai acopere C_i . În caz contrar, E este păstrat ca o excepție pozitivă.
5. Dacă E este acoperit de MU și XU, dar nu este acoperit de ML și XL (cazul 9 în Figura 9), atunci generalizează minimal pe ML pentru a acoperi E și pentru a rămâne mai puțin general decât MU. De asemenea elimină din MU elementele care nu îl acoperă pe E. Altfel continuă ca în pasul 4.

Tabelul 5: Rafinarea regulii cu un exemplu negativ

1. Dacă exemplul negativ E este acoperit de ML și nu este acoperit de XU (cazul 1 din Figura 9), atunci interacționează cu expertul în domeniu pentru a găsi explicația pentru care E este un pas de reducere de sarcină greșită. Dacă explicația EX este găsită, atunci generează o nouă condiție de tipul "cu excepția cazului în care" în spațiul de versiuni plauzibile și adaug-o la regulă. În caz contrar, păstrează E ca o excepție negativă.
2. Dacă E este acoperită de MU dar nu este acoperită de ML și de XU (cazul 2 din Figura 9) atunci interacționează cu expertul pentru a găsi explicația pentru care E este un pas de reducere de sarcină greșită. Dacă o explicație EX este găsită și are forma " I_i nu este un C_i ", unde C_i este un concept acoperit de MU, atunci specializează-l pe MU pentru a putea fi acoperit de C_i . În caz contrar, dacă un alt tip de explicație EX este găsită atunci învață o nouă condiție de forma "cu excepția cazului în care" bazată pe acest fapt, și adaugă această condiție la regulă.
3. Dacă E nu este acoperit de MU (cazurile 3,4,5 în Figura 9) sau este acoperit de XL (cazurile 5,6,7 în Figura 9) atunci regula nu trebuie să fie rafinată deoarece exemplul este clasificat corect ca negativ de regula curentă.
4. Dacă E este acoperit de ML și XU dar nu este acoperit de XL (cazul 8 din Figura 9) sau E este acoperit de MU și XU dar nu este acoperit de ML și XL (cazul 9 din Figura 9), atunci generalizează-l minimal pe XL pentru a-l acoperi pe E și specializează-l pe XU pentru a nu mai include conceptele care nu îl acoperă pe E.

Regula rafinată este prezentată în partea stângă a Figurii 10. Această regulă rafinată generează apoi reducerea sarcinii din partea de jos a Figurii 7. Deși acest exemplu este acoperit de condiția la limita inferioară plauzibilă a regulii, expertul în domeniu respinge reducerea ca fiind incorectă. Aceasta arată că condiția la limita inferioară plauzibilă nu este mai generală decât conceptul care se vrea învățat (cum ar fi fost în cazul algoritmului de eliminare al candidatului clasic) și are nevoie să fie specializată.

Această respingere a reducerii propusă de Disciple-RKF/COG inițiază generarea explicației în timpul căreia expertul în domeniu va trebui să ajute agentul să înțeleagă de ce pasul de reducere este incorect. Explicația acestei erori este aceea că Finland_1943 are doar o contribuție militară minoră la European_Axis_1943 și nu poate, de aceea să producă centrul de gravitate al acestei alianțe. Explicația efectivă a acestei erori (exprimată cu termeni din ontologia de obiecte) are forma :
“Finland_1943 are ca contribuție militară contribuția militară a Finland_1943 este contribuție militară minoră”.

Bazându-se pe această explicație a erorii, Disciple-RKF/COG generează un spațiu de versiuni plauzibile la care adaugă condiții de forma “cu excepția cazului în care” pe care le adaugă la reguli așa cum este indicat în partea dreaptă a Figurii 10. În viitor, această regulă se va aplica numai situațiilor în care condiția principală este satisfăcută și condiția de tipul “cu excepția cazului în care” nu este satisfăcută.

De observat este faptul că adăugarea condiției de tipul “cu excepția cazului în care” specializează ambele limite ale aplicabilității condiției regulii. Alte tipuri de explicații de erori pot conduce la modificări diferite ale regulii 4. De exemplu, explicația erorii ar fi putut avea forma “Finland_1943 nu este un aliat_major” dacă aliat_major ar fi fost o parte din ontologia de obiecte (ceea ce nu este adevărat). În acest caz, Disciple-RKF/COG, nu ar fi adăugat o condiție de tipul “cu excepția cazului în care” dar ar fi specializat ambele limite ale condiției principale pentru a acoperi numai “aliat_major”. Încă o posibilitate este de a găsi o caracteristică suplimentară a exemplelor pozitive ale regulii care nu este o caracteristică a exemplului negativ curent. Această caracteristică ar fi fost adăugată la obiectul corespunzător din condiția principală (atât în limita superioară cât și în limita inferioară). Exemple negative suplimentare pot conduce la condiții suplimentare de tipul “cu excepția cazului în care” și la specializări ale condiției principale.

Poate fi cazul ca explicația curentă a unui exemplu să conțină elemente care nu fac parte din ontologia de obiecte. În astfel de situații, Disciple-RKF/COG solicită astfel de elemente de la expertul în domeniu și le adaugă la ontologie ca noi concepte sau noi caracteristici. Așadar procesul de învățare este realizat într-un spațiu de reprezentare care evoluează în care ontologia de obiecte (care este utilizată ca o ierarhie generalizată pentru învățare) poate fi modificată în orice moment. Dacă ontologia este modificată, regulile învățate se poate să nu mai fie corecte. De aceea, regulile trebuie să fie reînvățate, fapt ce poate fi făcut automat dacă sistemul expert menține exemplele și explicațiile din care regulile au fost învățate. Totuși, exemple diferite și explicații de reguli conțin instanțe care au existat în scenarii diferite (de exemplu : al doilea război mondial sau Afghanistan 2001-2002). De aceea, Disciple-RKF/COG tine informații generice minimale ale exemplelor și explicațiilor care nu conțin nici o instanță și utilizează aceste exemple generalizate și explicații pentru a regenera regulile când ontologia de obiecte se schimbă.

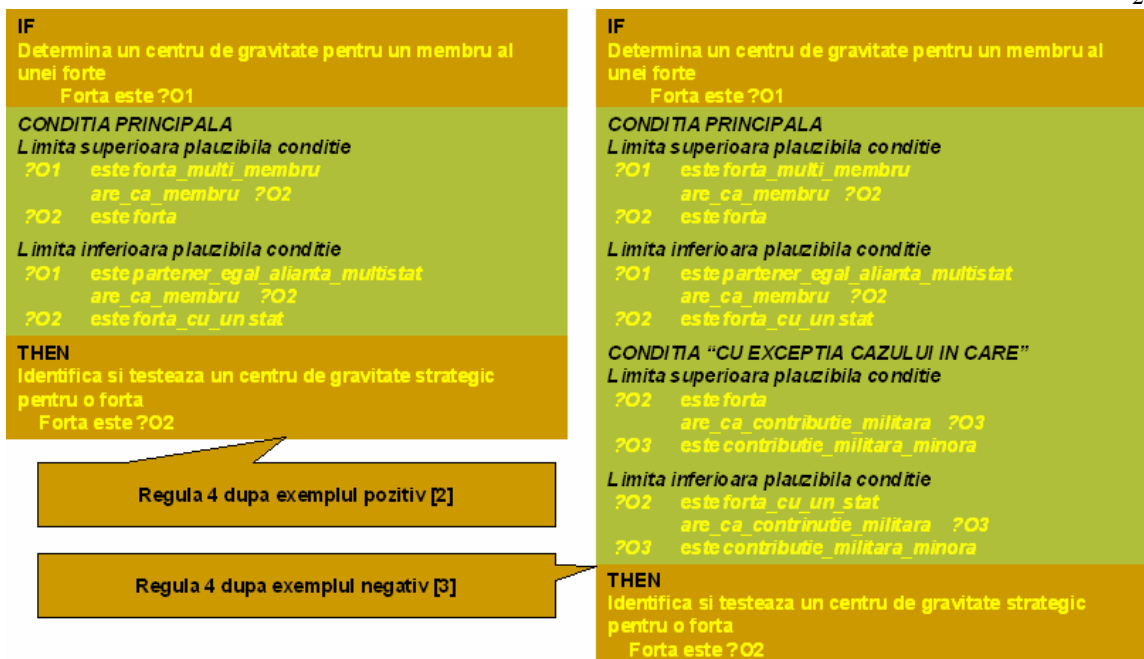


Figura 10

Principii de proiectare

Principiul de proiectare 6 (rezolvare de probleme și învățare integrată): Proiectați agentul instructibil astfel încât să suporte rezolvare de probleme și învățare integrată, unde expertul în domeniu și agentul instructibil rezolvă probleme în cooperare și agentul instructibil învață din contribuțiile primite în urma rezolvării problemelor cât și din propriile încercări de rezolvare”.

Principiul de proiectare 7 (predare și învățare integrată): Proiectați agentul pentru a suporta predare și învățare integrată, unde agentul instructibil ajută expertul în domeniu să predea (adică prin punerea de întrebări relevante), iar expertul în domeniu ajută agentul instructibil să învețe (adica oferindu-i exemple, ponturi și explicații).

Principiul de proiectare 8 (învățare multistrategică): Proiectați modulul de învățare al agentului instructibil astfel încât să implementeze învățarea multistrategică care integrează sinergistic câteva strategii de învățare beneficiind de avantajele puterilor lor complementare pentru a-si compensa reciproc slăbiciunile fiecăruia (Michalski și Tecuci, 1994).

Rezolvarea de probleme

Un agent instructibil Disciple-RKF/COG realizează sarcini de rezolvare de probleme folosind paradigma reducerii sarcinilor (Nilsson 1971; Powell and Schmidt 1988). În această paradigmă, o sarcină de rezolvare de problemă complexă este succesiv redusă la sarcini mai ușoare. Apoi soluțiile sarcinilor mai ușoare sunt găsite și aceste soluții sunt succesiv combinate în soluția sarcinii inițiale așa cum este ilustrat în Figura 11.

În abordarea Disciple-RKF/COG această strategie a fost rafinată astfel încât să poată fi utilizată cu ușurință atât de către expertul în domeniu (când predă agentului instructibil sau când contribuie la procesul comun de rezolvare de probleme) cât și pentru agentul instructibil (când rezolvă o problemă). Acest lucru a fost realizat prin introducerea de întrebări și răspunsuri care ghidează procesul de reduceri de sarcini, așa cum este ilustrat în Figura 11 și discutată mai în detaliu în (Bowman 2002).

În această abordare a reducerii sarcinilor rafinate, găsirea unei soluții a sarcinii de rezolvare a problemei (de exemplu T_0 în Figura 11) devine un proces iterativ în care, la fiecare pas, expertul în domeniu (sau agentul instructibil, depinzând de cine realizează rezolvarea de probleme) caută informație relevantă pentru a rezolva pe T_0 punând întrebarea Q_0 . Răspunsul A_0 identifică acel fragment de informație și conduce la reducerea sarcinii curente la sarcini mai simple (de exemplu T_1). Întrebări alternative corespund la strategii alternative de rezolvare a problemei. Răspunsuri multiple la o întrebare (de exemplu A_{11a} sau A_{11m}) corespund la soluții multiple. Compunerea soluției (de exemplu compunerea S_{11a}, \dots, S_{11m}) este de asemenea ghidată de întrebări și răspunsuri.




Figura 11

Figura 7 ilustrează procesul de descompunere cu un exemplu din problema centrului de greutate. În acest exemplu, expertul îi arată agentului cum să determine candidați pentru centrul de greutate pentru scenariul Sicily_1943 (al doilea război mondial la momentul invadării insulei Siciliei de către forțele aliate).

Principii de proiectare

Principiul de proiectare 9 (paradigma rezolvării de probleme generale): Bazați modulul de rezolvare de probleme al agentului instructibil pe paradigma rezolvării de probleme generale (cum ar fi reducerea de sarcini, căutarea în spațiul stărilor sau raționamentul bazat pe cazuri) care poate fi aplicată la o gamă largă de domenii de aplicație, dar modelează un cadru specializat pentru această paradigmă, pentru a ajuta experții în domeniu să își exprime modul lor de raționament și să învețe agentul instructibil.

4 AVANTAJE ȘI DEZAVANTAJE ALE SISTEMULUI EXPERT

Avantaje

“Disciple-RKF/COG” este o aplicație care este foarte ușor de folosit atât de către expertul în domeniu atunci când învață agentul instructibil să facă raționamente oferindu-i exemple și explicații și atunci când colaborează cu agentul instructibil pentru a rezolva probleme, cât și de către studenți datorită faptului că se poate comunica în limbaj natural, agentul instructibil generând un limbaj formalizat a cărui corectitudine utilizatorul o poate valida sau nu. De asemenea, interfața pusă la dispoziție este foarte prietenoasă cu utilizatorul.

Agentul instructibil își construiește ontologia de obiecte și poate deduce reguli pe baza cărora poate rezolva probleme și numai după ce expertul în domeniu i-a prezentat un singur exemplu însoțit de explicația corespunzătoare.

Disciple-RKF/COG învața nu numai din exemple și explicațiile primite de la expertul în domeniu ci și din propriile sale tentative de a rezolva probleme care se pot solda cu succes sau cu insucces.

Disciple-RKF/COG poate învăța atât din exemple pozitive cât și din exemple negative, adăugând regulilor clauze suplimentare (de tip rafinare) indicând care sunt situațiile în care regula nu trebuie aplicată, nu numai situații în care regulile se aplică.

Sistemul expert își poate reconfigura ontologia de obiecte deoarece reține toate exemplele și explicațiile pe care le-a primit de la expertul în domeniu, însă aceasta o face în mod minimal (eficient) reținând regulile generalizate la maxim posibil, deci fără să conțină vreo instanță pentru că odată cu modificarea ontologiei de obiecte instanțele nu mai sunt valabile și exemplele și explicațiile l-ar induce în eroare.

Sunt generate pentru fiecare regulă atât o condiție de maximă generalitate cât și o condiție de minimă generalitate astfel încât să poată fi identificate cât mai multe soluții; cele două condiții converg una spre cealaltă pe măsură ce ontologia de obiecte a agentului instructibil se îmbogățește și baza de cunoștințe conținând exemple și explicații oferite de expert se îmbogățește.

Atunci când expertul în domeniu nu specifică un concept deoarece i se pare trivial, agentul instructibil întreabă dacă conceptul nu a fost omis din greșală astfel încât să își poată completa ontologia de cunoștințe și raționamentul pentru rezolvarea problemei.

Agentul instructibil învață nu numai modul în care să rezolve probleme legate de centrul de gravitate al unui conflict militar ci și care sunt întrebările cheie pe care să le pună pentru a determina acest lucru; de asemenea poate determina factorii esențiali pentru care un centru de gravitate este strategic într-un conflict militar.

De asemenea, Disciple-RKF/COG este reconfigurabil astfel încât se pot specifica scenarii diferite cu parametri incompleți pentru ca va genera mai multe soluții precizând atât candidații pentru centrele de gravitate rezultate în urma etapei de identificare cât și centrul de gravitate strategic obținut în urma etapei de testare.

Dezavantaje

Agentul instructibil va întreba de fiecare dată expertul în domeniu după ce i-a fost prezentat exemplul și explicația în limbaj natural dacă formalizarea informațiilor pe care a făcut-o este corectă.

Deși dialogul de la expert în domeniu la agent instructibil se face în limbaj natural, dialogul de la agentul instructibil al expertul în domeniu se face în limbaj formalizat (inclusiv soluțiile sunt prezentate în limbaj formalizat).

Printre candidații pentru centrul de gravitate identificați de sistemul expert pot apărea și obiecte care nu sunt candidați pentru centrul de gravitate datorită condiției de maximă generalitate care a fost aplicată, aceasta neconvergând către soluția de minimă generalitate. Această situație se întâlnește însă doar atunci când numărul de exemple și de explicații oferite nu este prea mare astfel încât regulile care se aplică nu sunt rafinate.

Expertul în domeniu va trebui să își expună raționamentul pas cu pas și utilizând termeni de ontologia de obiecte astfel încât agentul instructibil să poată fi capabil să înțeleagă deși în mod obișnuit ar omite unii pași din raționament (deoarece îi par evidenti) și ar utiliza termeni de argou specifici domeniului.

Calitatea soluției oferite depinde foarte mult de dimensiunea ontologiei de obiecte cât și de dimensiunea bazei de cunoștințe astfel încât pentru a se obține rezultate cu un grad de precizie cât mai mare este necesar un efort inițial atât din partea expertului în domeniu cât și din partea inginerului de cunoștințe.

5 APLICAȚII ALE SISTEMULUI EXPERT

Utilizarea Disciple-RKF/COG la cursul

“Studii de Caz în Analiza Centrului de Gravitate”

Versiuni succesive ale Disciple-RKF/COG au fost utilizate atât în semestrele de toamnă și de primăvară ale cursului “Studii de Caz în Analiza Centrului de Gravitate” în ultimii doi ani academici și va continua să fie utilizat în continuare. Prezența la aceste cursuri a fost după cum urmează : 10 studenți în semestrul de toamnă 2001 (7 ofițeri ai armatei Statelor Unite și 3 studenți străini), 3 studenți în semestrul de primăvară 2001 (1 ofițer al armatei Statelor Unite și 2 studenți străini), 13 studenți în semestrul de toamnă 2002 (11 ofițeri ai armatei Statelor Unite și 2 studenți străini) și 10 studenți în semestrul de primăvară 2002 (2 ofițeri ai armatei Statelor Unite și 8 studenți străini). Studenții sunt locotenenți-colonel, coloneli sau generali din serviciul militar. La sfârșitul fiecărui curs studenții au completat formularele de evaluare despre Disciple-RKF/COG și modulele sale, opiniile lor referindu-se de la judecarea utilității sale în atingerea obiectivelor cursului până la judecarea abordării metodologice pentru rezolvarea problemei și până la judecarea ușurinței de utilizare și alte aspecte ale diferitelor module. Pe măsură ce capacitățile agenților instructibili utilizați au crescut, întrebările legate de evaluare au dobândit un răspuns din ce în ce mai bun. În continuare, spre exemplu, se prezintă evaluările a 13 studenți din semestrul de toamnă 2002 fiind general reprezentative pentru toate evaluările din toate celelalte semestre. Pe o scară de la 1 la 5 (dezacord puternic, dezacord, neutru, acord, acord puternic), 9 studenți și-au exprimat acordul și 4 studenți și-au exprimat acordul puternic referitor la afirmația “utilizarea Disciple-RKF/COG este o aplicație care se potrivește foarte bine cu obiectivele de învățare ale cursului”. Un student a fost neutru, dar 9 au fost de acord și ceilalți 3 au fost puternic de acord că “Disciple-RKF/COG m-a ajutat să învăț să realizez o analiză strategică a scenariului”. Un student nu a fost de acord, dar patru au fost de acord și opt au fost puternic de acord ca “utilizarea Disciple-RKF/COG a fost o experiență de învățare utilă”. În sfârșit, un student nu a fost de acord, nouă au fost de acord și alții 3 au fost puternic de acord ca “Disciple-RKF/COG ar trebui să fie utilizat pe viitor în versiuni ale acestui curs”.

Din câte se știe, este pentru prima dată când agenții inteligenței pentru identificarea și testarea centrului de gravitate strategic au fost dezvoltati și utilizați.

Utilizarea Disciple-RKF/COG în cursul

“Aplicații Militare ale Inteligenței Artificiale”

Mulți dintre studenții care au urmat cursul de “Analiza Centrului de Gravitate” în semestrul de toamnă, împreună cu alți studenți au urmat cursul de “Aplicații Militare ale Inteligenței Artificiale” în semestrul de primăvară. În semestrul de primăvară 2001 au urmat cursul 10 studenți (7 ofițeri ai armatei SUA și 3 studenți internaționali). În semestrul de primăvară 2002 au urmat cursul 15 ofițeri ai armatei SUA. În acest curs, studenții primesc o vedere de ansamblu asupra inteligenței artificiale ca și o introducere în utilizarea Disciple-RKF/COG. Ei sunt organizați în perechi de câte două persoane. Fiecare pereche i se dă un proiect de antrenare a Disciple-RKF/COG în conformitate cu propriul mod de raționament format în cadrul cursului de Analiza Centrului de Gravitate.

Așadar, studenții utilizează Disciple-RKF/COG ca experți în domeniu, spre diferență de cursul de “Analiza Centrului de Gravitate” unde ei erau utilizatori ai agentului instructibil.

În ceea ce privește dezvoltarea agentului, cursul de “Aplicații Militare ale Inteligenței Artificiale” este structurat în două părți, o parte de învățare în timpul căreia studenții (care sunt experți militari) învață să folosească Disciple-RKF/COG și o parte de experimentare în care fiecare echipă își antrenează propriul agent.

În semestrul de primăvară 2001 fiecare din cele cinci echipe a învățat să își folosească agentul instructibil folosind un scenariu diferit. Apoi, în ultimele trei ore de curs, echipele au participat într-un experiment controlat de pregătire a agenților care a fost filmat în totalitate. Fiecărei echipe i s-a dat o copie a Disciple-RKF/COG care conținea o ontologie de obiecte generică dar nici o instanță specifică, nici o sarcină și nici o regulă. Fiecare echipă a primit un raport de 7 pagini descriind un scenariu nou (scenariul Okinawa) și a fost rugată să antreneze Disciple-RKF/COG pentru a identifica centrul de gravitate. După fiecare etapă importantă a antrenării agentului și dezvoltare a bazei de cunoștințe (specificare scenariu, modelare, învățare de reguli, rafinare de reguli) un inginer de cunoștințe a verificat munca echipei și echipa a făcut atunci eventuale corecții necesare sub supravegherea inginerului de cunoștințe. Partea stângă a graficelor din Figura 12 sunt un sumar al caracteristicilor medii ale bazelor de cunoștințe dezvoltate în experimentul din primăvara 2001. De observat că, în medie, cei cinci agenți antrenați de cele 5 echipe au adunat 179.2 fapte pentru a specifica scenariul Okinawa. Ei au învățat de asemenea 20.2 sarcini și 18.8 reguli pentru identificarea candidaților pentru centrul de gravitate strategic. Desi evident incomplete (datorita utilizării unui singur scenariu de antrenare și datorită antrenării incomplete pentru scenariul în cauză), bazele de cunoștințe au fost suficient de bune pentru a identifica centrul de gravitate nu numai pentru scenariul Okinawa dar și pentru scenariile folosite pentru proiecte. La finalul acestui experiment, studenții au completat un chestionar detaliat despre componentele principale ale agentului instructibil. Unul dintre cele mai semnificative rezultate a fost faptul că 7 din 10 studenți au fost de acord, 1 student a fost puternic de acord și 2 studenți s-au declarat neutri referitor la următoarea afirmație : “Consider că un expert în domeniu poate folosi Disciple-RKF/COG pentru a dezvolta un agent instructibil cu o asistență limitată din partea inginerului de cunoștințe”. Experimentul a fost condus utilizându-se o versiune anterioară a Disciple-RKF/COG (Boicu, 2001).




Figura 12

Semestrul de primăvară al anului 2002 la cursul de “Aplicații Militare ale Inteligenței artificiale” a fost organizat puțin diferit. Toți studenții au învățat să folosească Disciple-RKF/COG în timpul cursului folosind scenariul invaziei Siciliei de către forțele aliate din timpul celui de-al doilea război mondial ca scenariu de antrenament.

Apoi, ca o parte a experienței lor cu Disciple-RKF/COG, fiecare din cele 7 echipe și-a antrenat propriul agent instructibil folosind un scenariu diferit. În toate cazurile cu excepția a unuia singur, scenariile au fost cele din semestrul de toamnă 2002 de la cursul de “Analiza Centrului de Gravitate”.

Partea dreapta a graficului din Figura 12 arată caracteristicile medii ale bazelor de cunoștințe dezvoltate de cele 7 echipe. În primul rând, trebuie subliniat ca de această data experții si-au antrenat agentii nu numai pentru a identifica centrul strategic de gravitate pentru un scenariu dat, ci și pentru a le testa, care implică un raționament mult mai complex.

De observat este faptul că ontologia de obiecte inițială în semestrul de primăvară 2002 a fost de două ori mai mare decât ontologia din experimentul din semestrul de primăvară 2001 (397 față de 223 de obiecte și caracteristici). Mai mult, ontologia a fost extinsă puțin în timpul experimentului cu o medie de 1.28 caracteristici, arătând capacitatea Disciple-RKF/COG de a învăța cu un limbaj propriu de reprezentare care evoluează.. Această creștere a ontologiei, din semestrul de primavara 2001 în semestrul de primăvară 2002 a fost cerută de raționamente adiționale pentru testarea candidaților centrelor de gravitate.

De observat de asemenea că agentii instructibili din semestrul de primăvară 2001 nu au avut nici o sarcina sau regula inițială de raționament. Agentii instructibili din experimentul din semestrul de primăvară 2002 au avut 14 sarcini inițiale și 15 reguli inițiale care au permis agenților să realizeze raționamente. De exemplu, aceste sarcini și regulii au permis Disciple-RKF/COG să reducă sarcina “Identificați și testați un candidat pentru centrul de gravitate strategic pentru scenariul Sicily_1943” la sarcina “Identificați și testați un candidat pentru centrul de gravitate strategic referitor la poporul US_1943”.

Apoi echipa a avut de testat modul în care agentul identifică și testează candidații pentru centrul de gravitate strategica unei forțe inamice raportat la poporul US_1943 (de asemenea raportat și la alte aspecte cum ar fi guvernul, armata sau economia). În medie, fiecare echipă a învățat agentul său 35 de sarcini și 31 de reguli. Cu toate acestea, bazele de cunoștințe dezvoltate au fost tot incomplete din aceleasi motive pentru cele explicate la semestrul de primăvară 2001. De asemenea, iarăși, bazele de cunoștințe au fost suficient de bune pentru a permite fiecărui agent instructibil să analizeze scenariile celorlalte echipe.

La sfârșitul semestrului de toamnă 2002 9 din cei 15 studenți au fost de acord, 2 au fost puternic de acord și 2 au fost neutri referitor la afirmația : “Consider că un expert în domeniu poate utiliza Disciple-RKF/COG pentru a construi un agent, cu asistență limitată din partea inginerului de cunoștințe” în ciuda faptului că de această data antrenarea solicitată a fost mult mai complexă decât cea din semestrul de primăvară 2001.

Consider că aceste experimente au reprezentat un succes semnificativ, demonstrând că experții în domeniu își pot antrena proprii lor agenți personali cu propria lor experiență de rezolvare de probleme și cu asistență limitată din partea inginerilor de cunoștințe.

6 DEMO. O SESIUNE SCRISĂ PENTRU SISTEM

Rezultatele experimentale arată că etapa de Modelare este cea mai provocatoare pentru expertul în domeniu în procesul de pregătire a agentului instructibil. Din acest motiv, a fost dezvoltat un consilier de modelare pentru a ajuta expertul în domeniu în cadrul acestei activități. Figura 5 prezintă interfața acestui nou modul pentru “Disciple-RKF”.

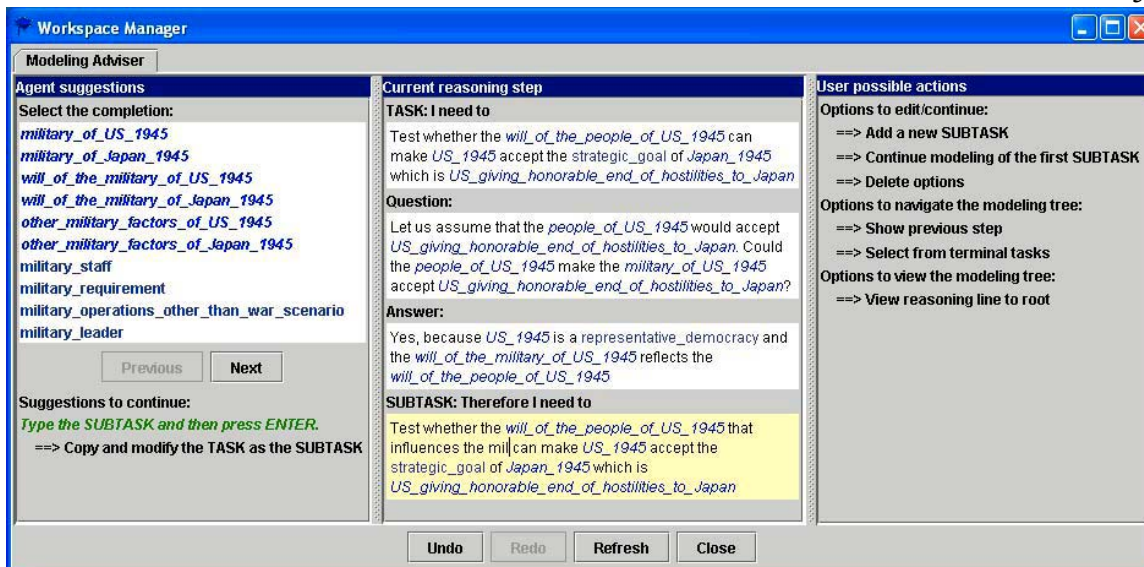


Figura 13

Partea din mijloc a ecranului conține pasul curent de reducere a sarcinii pe care expertul îl compune. La fiecare stare din acest proces, partea dreaptă a ecranului prezintă toate acțiunile care pot fi realizate în acest pas, iar partea stângă a ecranului prezintă acțiunea pe care consilierul de modelare îl recomandă. De exemplu, pentru a specifica subsarcina curentă, consilierul de modelare a sugerat expertului în domeniu să copieze și să modifice sarcina. Consilierul de modelare poate totodată să sugereze întrebarea care să fie pusă sau răspunsul la întrebare. Așa cum a fost precizat și mai sus, expertul în domeniu își exprimă raționamentul în limba engleză. Totuși, de fiecare dată când începe să scrie un cuvânt, agentul instructibil listează în partea stângă a ecranului toate instanțele și conceptele din baza de cunoștințe care corespund caracterelor tastate până la momentul curent. Această facilitate este utilă din două motive diferite : facilitează datele de intrare din partea expertului în domeniu și ajută agentul instructibil să “înțeleagă” frazele expertului în domeniu.

Întâi, Disciple-RKF/COG ghidează studentul pentru a identifica și descrie aspectele unui scenariu de război care sunt relevante pentru analiza centrului de gravitate. Interacțiunea student-agent instructibil este ilustrată în figura 14. Partea stângă a ferestrei este tabla de conținuturi, ale carei elemente indică aspecte diferite ale scenariului. Când studentul accesează unul dintre aspecte, partea dreaptă a ferestrei indică întrebări specifice menite să preia de la student o descriere a aspectului sau să actualizeze descrierea specificată anterior. Răspunsurile studentului conduc la generarea de noi elemente în partea stângă a ferestrei și la punerea de noi întrebări din partea agentului.

Studentul nu trebuie să răspundă la toate întrebările și Disciple-RKF/COG poate fi întrebat la orice moment să identifice și să testeze un candidat pentru centrul de gravitate strategic pentru specificarea curentă a scenariului. Figura 15 prezintă interfața vizualizatorului de soluții.

În partea stângă a Disciple-RKF/COG sunt prezentați candidații pentru centrele de gravitate strategice pentru fiecare forță inamică. Când studentul accesează una dintre ele, justificarea de ce a fost identificat drept candidat apare sau justificarea rezultatului de testare este afișat în partea dreaptă a vizualizatorului (depinzând de care meniu este ales de către student).

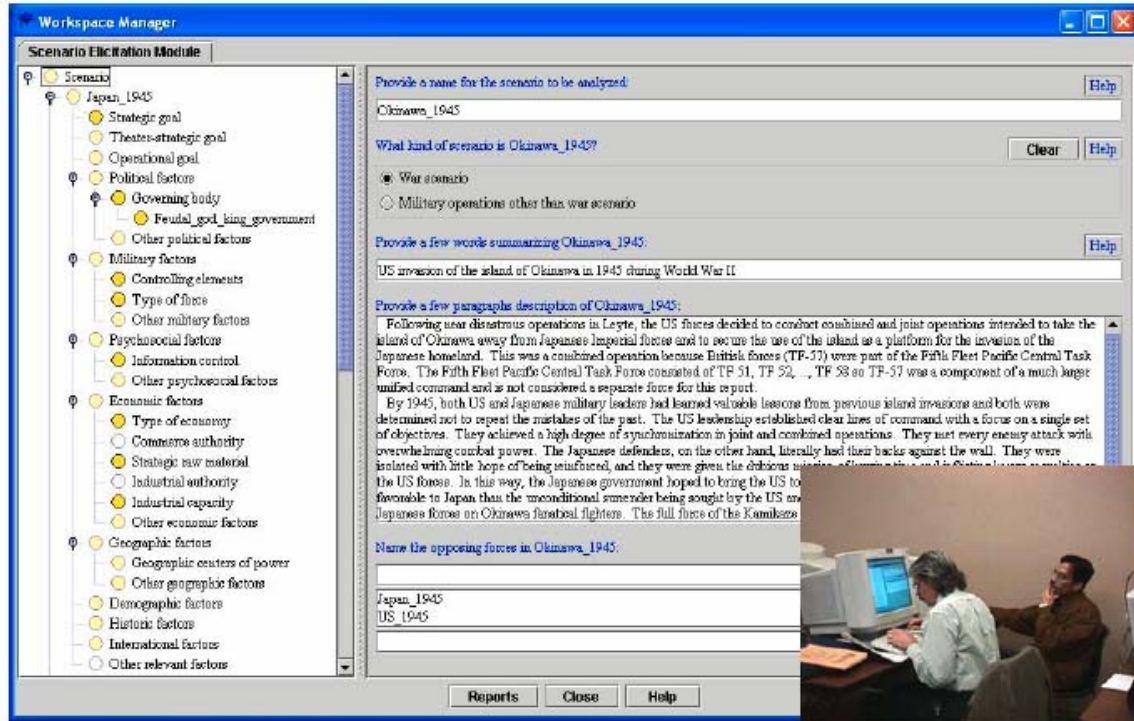


figura 14

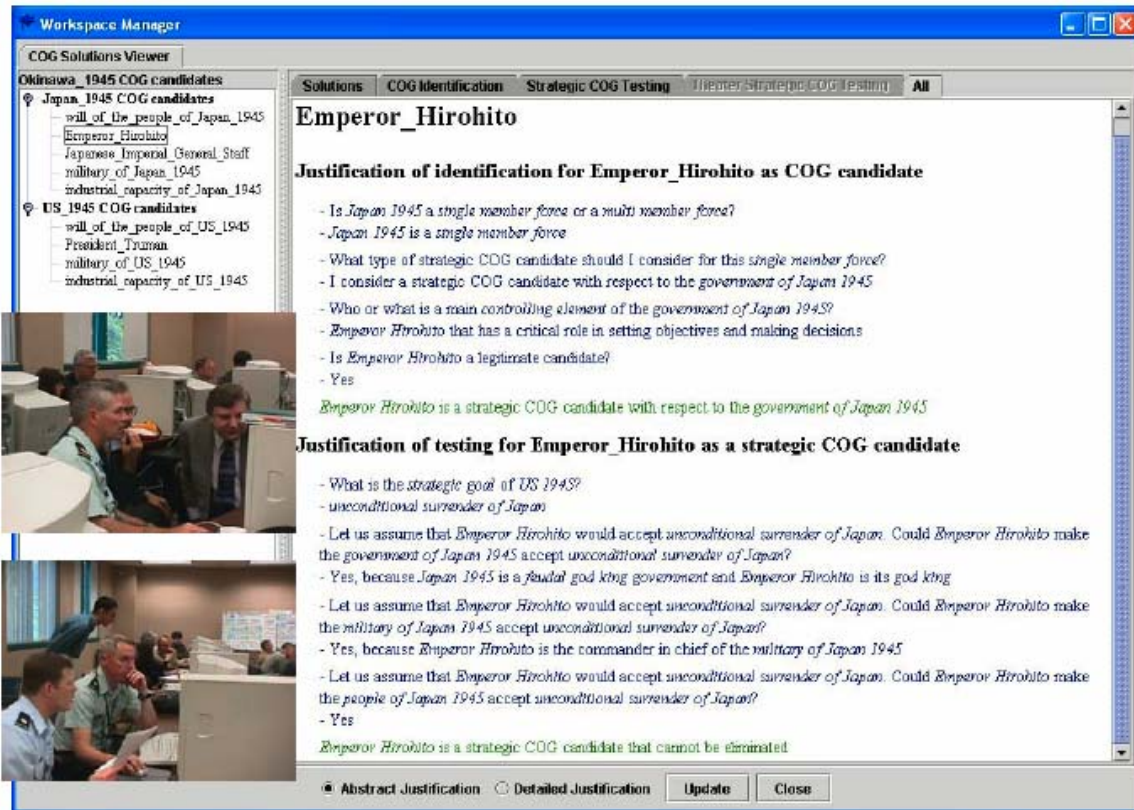


figura 15

La sfârșitul analizei, Disciple-RKF/COG generează un raport conținând atât descrierea scenariului cât și analiza candidaților de centru de gravitate identificați, așa cum se poate observa în figura 16. Studentul poate utiliza apoi un editor de text pentru a finaliza raportul generat de Disciple-RKF/COG, fiind necesar să analizeze critic logica Disciple-RKF/COG să o completeze și să o corecteze sau chiar să o respingă și să producă un mod de raționament diferit.

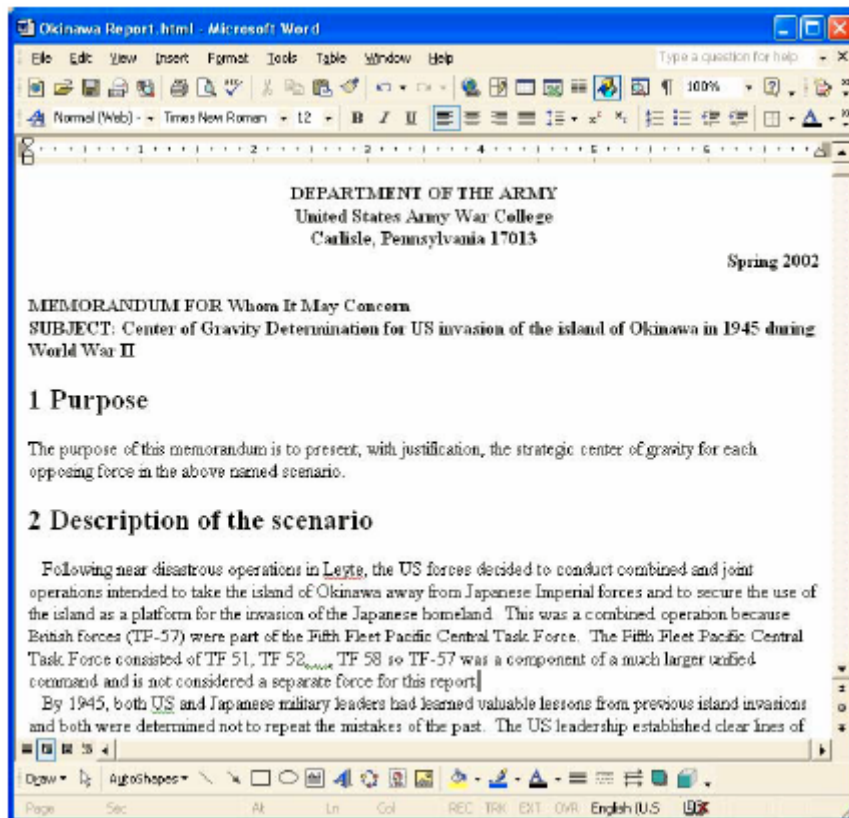


Figura 16

7 CONCLUZII ȘI PLANURI DE VIITOR

Aplicațiile bazate pe domenii nu reprezintă o activitate obișnuită pentru cercetătorii din universități. Experiența prezentată în acest referat arată, totuși, că poate fi foarte benefic chiar și pentru scopuri legate de dezvoltarea bazelor de cunoștințe. Într-adevăr cercetările realizate pe baze de cunoștințe și dezvoltare de agenți de către experți în domeniu au beneficiat de domeniul analizei centrului de gravitate care au ridicat o problema complexă, cu numeroase cunoștințe implicate, provocatoare. Această cercetare a beneficiat și de aplicarea ei practică în educație ambele cursuri de “Analiză a Centrului de Gravitate” cât și “Aplicații Militare ale Inteligenței Artificiale” permițând testarea agenților instructibil cu experți în domeniu, rezultând validarea metodelor implementate și oferind noi idei pentru îmbunătățire.

Pe de altă parte, cercetarea în domeniul centrului de gravitate a beneficiat de cercetarea în inteligența artificială în care agentul instructibil a ajutat la clarificarea și formalizarea procesului de analiză a centrului de gravitate și a condus practic la prima sa abordare computațională. De asemenea, aplicația inovativă a inteligenței artificiale și a centrului de gravitate în educație a îmbunătățit semnificativ cele doua cursuri.

Există două tendințe de îmbunătățire. Prima tendință o reprezintă dezvoltarea unei noi versiuni a Disciple-RKF/COG care să fie utilizată nu numai în Academiile Militare din Statele Unite ci și în alte colegii pentru ofițeri cum ar fi Colegiul Naval sau Colegiul Aeronautic. A doua tendință o reprezintă demararea unui nou proiect cu Academia Militară din Statele Unite care are ca scop dezvoltarea unui cadru care integrează cercetările din domeniul inteligenței artificiale cu dezvoltarea de sisteme prototip utilizabile în educație și în practică.