

Ch.A.M.P. – Sistem pentru evaluarea și modelarea contribuției participanților la un Chat

Mihai Dascălu^{1,2}, Ștefan Trăușan-Matu^{1,3}

¹Universitatea „Politehnica” București,
Splaiul Independenței, Nr 313, 060042, București
E-mail: stefan.trausan@cs.pub.ro

²CCT S.R.L.
Str. Gheorghe Brătianu, Nr. 30, București
E-mail: mihai.dascalu@cct.ro

³Institutul de Cercetări în Inteligența Artificială,
Calea 13 Septembrie nr. 13, București

Rezumat. Lucrarea prezintă un sistem dezvoltat în scopul evaluării competențelor și a evoluției participanților din cadrul unui mediu colaborativ. Pentru a obține o abordare de ansamblu au fost luate în considerare două scenarii: unul cantitativ bazat pe rețele sociale și pe numărul de replici interschimbate între participanți, iar al doilea, calitativ, bazat pe o analiză semantică a conținutului fiecărei replici. O componentă importantă a sistemului este cea de vizualizare prin intermediul căreia se poate observa și modela rețeaua socială, se poate analiza evoluția globală la nivelul întregului chat, la nivelul unui fir de discuție, dar și la nivelul fiecărui participant în parte, și se poate evidenția contribuția fiecărui participant prin statisticile generate pe baza diverselor metrice. De asemenea, alte module au fost dezvoltate în vederea evaluării manuale a fiecărui chat pentru a obține corpusul de referință, pentru a compara notele cu rezultatele obținute în urma analizei automate și pentru a învăța din corpus folosind LSA și Wordnet.

Cuvinte cheie: învățare colaborativă asistată de calculator (Computer-Supported Collaborative Learning), evaluare, adnotare, rețele sociale, web semantic, Analiză semantică latentă (LSA).

1. Introducere

Dimensiunea colaborativă a devenit din ce în ce mai importantă odată cu dezvoltarea și popularizarea noilor medii de comunicare de tip mesagerie instantanee („chat”) sau forum de discuții, datorită beneficiilor directe asupra rezultatului unei anumite teme dezbătute prin efectul său sinergic.

Odată cu dezvoltarea laturii sociale a web-ului și considerarea și a laturii semantice, noile canale de comunicații au devenit o alternativă viabilă la modalitățile clasice de învățare, apărând astfel învățarea colaborativă asistată de calculator (Computer Supported Collaborative Learning, CSCL, vezi Stahl, 2006).

Un aspect esențial al mediilor colaborative, și implicit al discuțiilor de tip chat este dimensiunea socială, dezvoltarea laturii relaționale din fiecare. Pe lângă dezvoltarea perspectivei cognitive, mediile interactive pe web încurajează și latura social-emoțională, permițând totodată și accesul oricui, indiferent de localizarea geografică. Posibilitatea și încurajarea învățatului și a rezolvării de probleme prin intermediul chat-ului sunt din ce în ce mai întâlnite în educație (Dascălu et al., 2008; Stahl, 2006; Trăușan-Matu et al., 2004; Trăușan-Matu et al., 2007; Trăușan-Matu și Rebedea, 2009; Wee și Looi, 2007), oferind soluții viabile la procesele clasice. Provocarea majoră în această etapă este volumul de date care trebuie analizate și, implicit, a timpului mare necesar evaluării manuale.

În acest context a apărut și dificultatea discernerii corectitudinii informațiilor prezentate sau a analizei participării fiecărui participant într-o conversație. Astfel, evaluarea automată este necesară pentru a oferi o idee cât mai concretă despre evoluția sau contribuția fiecărui participant. Scopul în sine nu este înlocuirea tutorelui, ci facilitarea și scăderea drastică a timpului necesar evaluării, oferind astfel posibilitatea creșterea numărului de exerciții și focusarea pe activități într-adevăr creative. Totodată, specificul fiecărui domeniu, în cazul de față al tehnologiilor web – Tehnologia Informației, facilitează procesul de evaluare din prisma faptului că restrângerea domeniului și prezentarea de termeni specifici determină o învățare automată mai eficientă.

Un alt aspect care trebuie menționat este dualitatea perspectivei de analiză. Pe de o parte se dorește evaluarea cunoștințelor existente și a celor dobândite, astfel evaluarea orientându-se către competențele efective ale participanților dintr-un chat. De cealaltă parte se caută dezvoltarea laturii sociale, a legăturilor dintre participanți, punându-se în acest caz accent pe importanța persoanei văzută ca o exprimare a centralității din perspectiva rețelelor sociale. Astfel, se dorește o balansare între procesul de evaluare al competențelor și cel al importanței în cadrul comunității (în cadrul nostru restrânsă la nivelul unui singur chat) în vederea obținerii unei imagini holistice asupra fiecărui participant.

Lucrarea prezintă și evaluează un sistem automat de notare prin compararea rezultatelor cu cele obținute prin evaluarea manuală a conversațiilor. Intrarea pentru sistem este formată din replici, ordonarea lor și legăturile explicite (conform Holmer et al., 2006) dintre ele.

Pentru a se obține o imagine de ansamblu au fost luați în considerare o serie de factori specifici rețelelor sociale aplicați atât asupra numărului de replici interschimbate cât și asupra fiecărei replici evaluate din punctul de vedere al conținutului său semantic.

Prima secțiune prezintă factorii de interes asociați rețelelor sociale, sistemul de evaluare, graficele obținute și modulul pentru adnotarea manuală. Următoarea secțiune se axează pe analiza semantică latentă (LSA, Landauer et al., 1998; Manning și Schutze, 1999) și utilizarea sa în cadrul proiectului, urmată de acuratețea procesului de notare al participanților.

2. Factorii utilizați și sistemul de evaluare

2.1 Procesul de evaluare

În vederea obținerii unei note cât mai relevante, o serie de metrici au fost luate în calcul pornind de la cele mai simple precum numărul de caractere scrise de fiecare participant și ajungând până la un algoritm care determină rangul utilizatorilor.

Numărul de caractere sau consecvența unui participant cotate drept numărul mediu de caractere per replică oferă doar informații cantitative despre implicarea sa din cadrul conversației. Pentru a obține o oglindire cât mai bună a impactului fiecărui participant este necesară găsirea unui echilibru între analiza brută, cantitativă, și abordarea calitativă, mult mai importantă, determinată de conținutul efectiv al fiecărei replici.

Astfel, este necesară analiza rețelei sociale obținută din interschimbul de replici. Din acest punct de vedere sunt construite două grafuri în care nodurile sunt participanții, iar arcele construite pe baza legăturilor explicite din cadrul mediului colaborativ (Holmer et al., 2006) au pe rând următoarele conotații:

- Numărul de replici aferente schimbului de replici între participanți (abordarea cantitativă);

- Scorul fiecărei replici determinată după mecanismul descris ulterior.

Datorită mediului colaborativ și a numărului relativ restrâns de participanți din cadrul unui același chat, au fost calculate trei metrici de tip centralitate: apropierea („closeness”), centralitatea grafului și valorile proprii.

Apropierea evaluează centralitatea raportată la inversul distanței minime între nodul curent și toate celelalte noduri. Centralitatea grafului este o apropiere relativă reprezentând distanța maximă între nodul considerat și celelalte noduri. Din punct de vedere computațional, cele două metrici sunt calculate cu o complexitate $O(n^3)$ folosind algoritmul Floyd-Warshall care determină distanțele minime între oricare două noduri (Cormen et al., 2001).

Valorile proprii atașează fiecărui nod un scor relativ după următorul principiu: o conexiune la un nod cu un scor mai mare este mai importantă decât o mulțime de conexiuni la participanți cotați inferior. De asemenea, în evaluarea unui participant s-a pornit de la următoarele prezumții:

- pentru toate valorile negative se iau în considerare valorile lor absolute;
- pentru valori atât pozitive cât și negative contribuția se calculează raportat la valorile minime și maxime;
- pentru valori strict pozitive scalarea se face între 0 și valoarea maximă.

O altă metrică evaluată este rangul unui participant bazat pe algoritmul Google Page Rank (<http://www.smashingmagazine.com/2007/06/05/google-pagerank-what-do-we-really-know-about-it/>). Rangul utilizatorului curent este influențat de rangul celorlalți participanți direct conectați cu acesta. Astfel scorul curent este determinată de aportul propriu-zis de informații al replicilor interschimbate și de rangul participanților care dialoghează cu utilizatorul curent. Pentru evaluarea rangului se folosesc metode numerice de rezolvare a algoritmului, mai exact o metodă iterativă bazată pe următoarea ecuație:

$$UR(A) = (1 - d) + d \left(\frac{UR(t_1)}{c(t_1)} + \dots + \frac{UR(t_n)}{c(t_n)} \right) \quad (1)$$

unde UR= rangul utilizatorului; c(ti) = numărul / scorul replicilor interschimbate între ti și A; d= o constantă (în implementarea curentă 0,85) folosită pentru convergența mai rapidă a sistemului.

Toate aceste metrice specifice teoriei grafurilor și rețelelor sociale sunt calculate pe baza a două grafuri reprezentate prin matrici de adiacență care urmăresc cele două abordări:

- cantitativă, bazată pe numărul de replici interschimbate între participanți conform legăturilor explicite definite în sistemul Polyphony (Trăușan-Matu și Rebedea, 2009; Holmer et al., 2006);
- calitativă în care fiecare evaluarea fiecărei replici ia în considerare pe lângă lungimea propriu-zisă și:
 - numărul de cuvinte cheie rămase după eliminarea cuvintelor fără importanță („stop words”), corectarea erorilor („spell-checking”) și extragerea rădăcinii („stemming”) = lungimea_prelucrată;
 - numărul de apariții ale unui cuvânt și relevanța lor raportată la un set de cuvinte cheie = nr_apariții;
 - nivelul pe care replica se află în cadrul firului de discuție = înălțime;

Luând în considerare factorii enumerați, ponderile au fost atribuite în vederea unei cât mai bune exprimări a impactului aferent în cadrul notării finale, precum și în vederea maximizării corelării cu notarea manuală:

$$nota_{empirica} = \frac{\frac{lungime}{6} + \frac{lungimere_prelucrata}{6}}{1 + \frac{1}{inaltime}} * \left(1 + \frac{1}{10} * relevanta\right), \quad (2)$$

$$relevanta = \sum_k \ln(nr_aparitii_k + 1) * Sim(cuvant_k, lista_cuvinie_cheie),$$

unde relevanța este calculată pentru toate cuvintele rămase în urma prelucrării inițiale, iar similaritatea va fi prezentată în următoarea secțiune.

Pe baza acestei note empirice se calculează scorul finală a unei replici:

$$nota_{finala} = nota_{replica_precedenta} + coeficient * nota_{empirica} \quad (3)$$

unde coeficientul este determinat prin combinarea tipurilor replicii curente și tipul replicii precedente. În evaluarea coeficientului sunt mai întâi identificate actele de vorbire (verbe, semne de punctuație, anumite cuvinte

cheie), urmând gruparea replicilor în următoarele categorii: negații, aprobări, întrebări și afirmații. Valorile efective ale coeficientului sunt extrase dintr-o matrice predefinită.

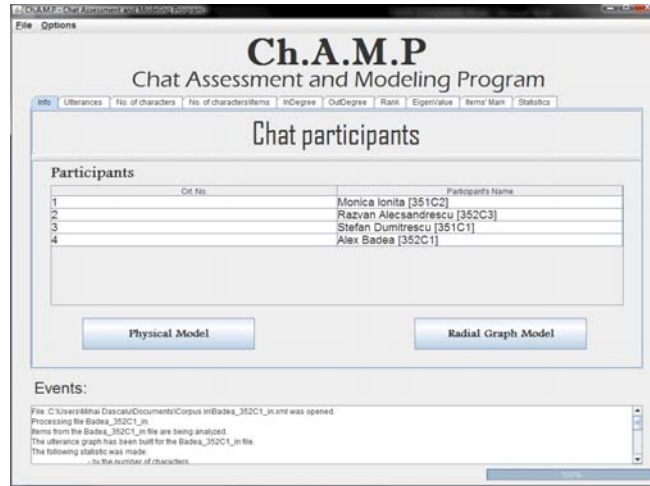


Figura 1. Interfața principală a sistemului ChAMP

În vederea determinării scorului final al unui participant, toți factorii menționați anterior, aplicați atât în cazul abordării cantitative, cât și în cazul celei calitative, sunt ponderați:

$$nota_finala_i = \sum_k ponderea_k * nota_factor_{k,i}, \quad (4)$$

unde i este participantul curent și k este metrica luată în considerare.

2.2 Prelucrări specifice și vizualizarea rezultatelor

O problemă serioasă întâlnită în mediile de tip chat este determinată de numărul mare de cuvinte scrise greșit, de abrevieri sau emoticoane (de exemplu, „:”)”, „;”)”). Pentru rezolvarea acestor dificultăți întâmpinate, pe lângă folosirea unei liste de cuvinte irelevante („stop words”), s-a utilizat Jazzy (<http://jazzy.sourceforge.net>) drept corector morfologic („spellchecker”), cu câteva modificări: de exemplu adăugarea unui spațiu în interiorul unui cuvânt și verificarea dacă distanța Levenshtein obținută este mai mică, sau verificarea corectitudinii folosind WordNet-ul drept dicționar.

Pentru extragerea rădăcinii („stemming”), a fost ales Snowball (<http://snowball.tartarus.org/>) întrucât au fost obținute cele mai bune rezultate în contextul cuvintelor întâlnite în chat-uri, raportat la alte soluții precum Porter (<http://tartarus.org/~martin/PorterStemmer/>) sau Lovin (http://sourceforge.net/project/showfiles.php?group_id=24260). În plus, chiar pe pagina de web a programului Porter este recomandat Snowball.

În scopul vizualizării rețelelor sociale două modele au fost create pornind de la platforma Prefuse (<http://prefuse.org/>):

- un model fizic în care participanții sunt considerați planete, fiecare cu masa aferentă; lungimea legăturii între doi participanți se bazează pe notele replicilor interschimbate, iar coeficienții de elasticitate sunt de asemenea modificați pentru a obține un model cât mai realist.

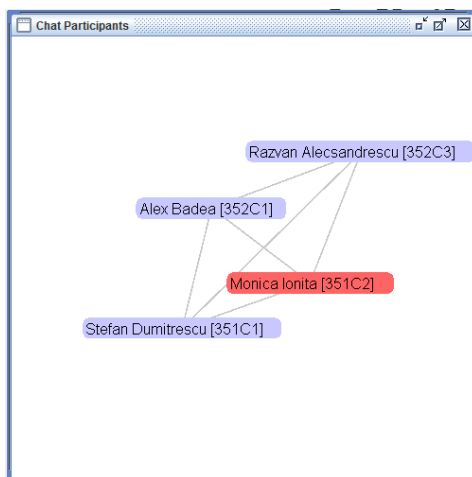


Figura 2. Abordare bazată pe un model fizic pentru vizualizarea rețelelor sociale

- un model radial orientat pe centralitatea perspectivei de vizualizare – graful este concentrat asupra participantului selectat și vecinii lui; este posibilă vizualizarea rețelei din perspectiva oricărui utilizator, cu o adâncime maximă admisă și căutarea participanților într-o rețea socială extinsă.

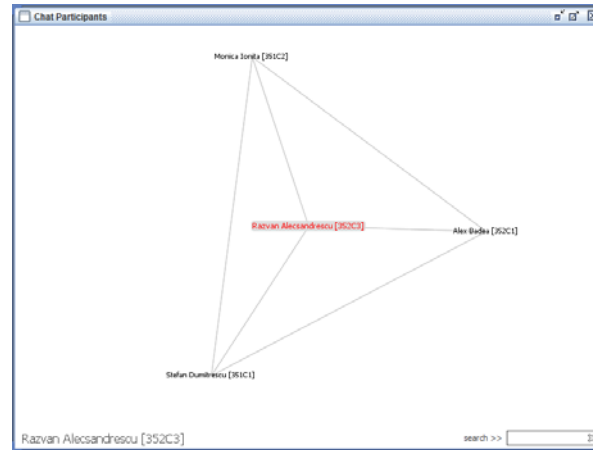


Figura 3. Reprezentare radială a rețelei sociale, incluzând facilități de căutare a participanților

Pentru fiecare factor specific rețelelor sociale, precum și pentru statisticile finale, grafice de tipul bară („bar chart”) sunt generate în vederea unei vizualizări mai clare și a unei mai bune înțelegeri a contribuției/implicării fiecărui participant.




Figura 4. Statistici generate pentru fiecare factor luat în considerare (inclusiv numărul de replici interschimbate / notele replicilor și statisticile finale ale participanților)

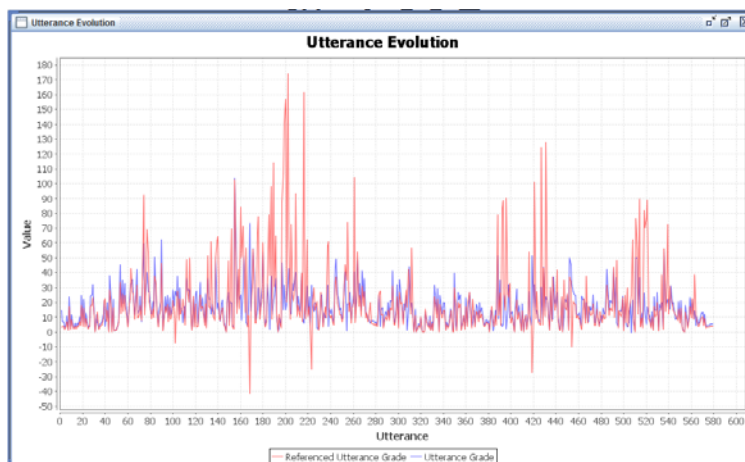


Figura 5. Evoluția replicilor raportat la întreaga conversație

Pe de altă parte sistemul oferă posibilitatea vizualizării evoluției globale a conversației pornind de la scorul final al fiecărei replici. În cadrul evoluției pot apărea și valori negative în funcție de părțile de vorbire identificate și de tipurile replicilor curente, respectiv precedente. De asemenea se pot genera și grafice doar pe anumite fire de discuție, având punct de plecare prima replică de interes.

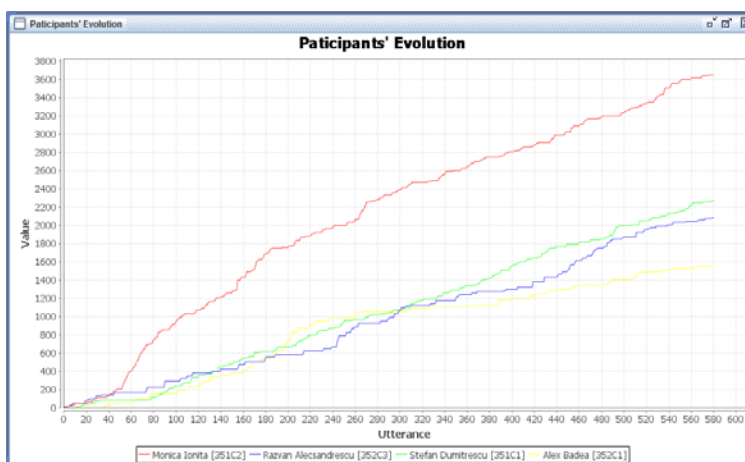


Figura 6. Evoluția replicilor raportat la întreaga conversație

Similar cu evoluția replicilor este posibilă vizualizarea evoluției participanților prin însumarea contribuțiilor personale până într-un punct predefinit din chat.

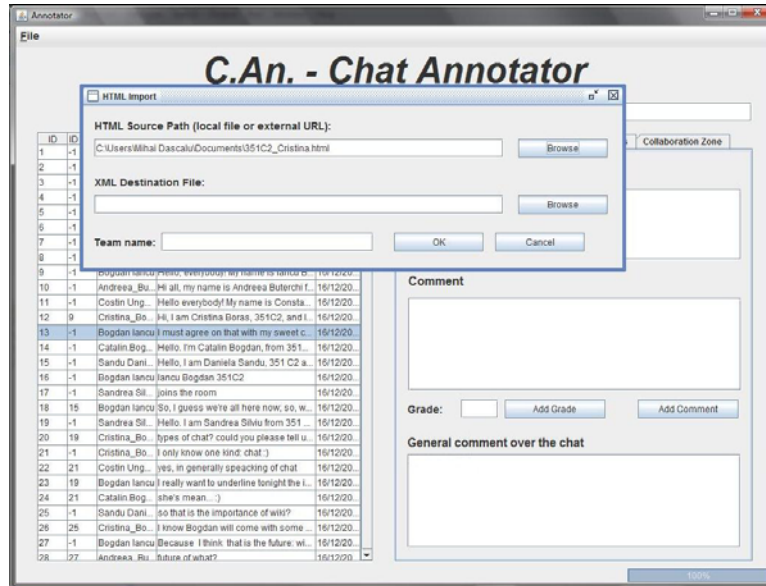


Figura 7. Interfața modulului de evaluare manuală

Un modul foarte important în evaluarea performanțelor sistemului este adnotarea manuală necesar construirii corpului și în cadrul procesului de învățare. Acest sistem permite următoarele facilități:

- importul chat-urilor din format HTML și salvarea lor într-un fișier XML;
- adăugarea de adnotări la nivel de replici, participant (note la nivel de replică, înșiruire/bloc de 20 de replici sau global la nivelul întregii conversații), zone de colaborare intensă;
- identificarea cuvintelor cheie în urma analizei evoluției chatului;
- salvarea legăturilor implicite împreună cu tipul referințelor și șabloanele identificate.

3. Analiză Semantică Latentă

3.1. Prezentare generală

LSA este o tehnică utilizată în cadrul prelucrării limbajului natural în cadrul căreia se evaluează relațiile între un set de documente și termenii conținuți, reprezentarea acestora într-un spațiu vectorial care ulterior, prin proiecția termenilor, se va grupa în seturi de concepte relativ la corpusul de documente folosit pentru învățare.




Figura 8. Interfața modulului de învățare folosind LSA

LSA folosește o matrice termen-document bidimensională în care se înregistrează numărul de apariții ale termenului în diversele documente. Este vorba de o matrice rară care corespunde rădăcinilor cuvintelor care apar în documente și care reprezintă coloanele matricii.

LSA transformă matricea de apariții în relații între termeni și concepte, respectiv între concepte și documente, astfel modelând indirect corespondența dintre termeni și documente prin intermediul conceptelor.

LSA este utilizat în cadrul procesului de evaluare în vederea estimării corelării cu întregul chat și a relevanței fiecărei replici relativ la domeniul

luat în considerare – în cazul de față IT, cu accent pe interacțiunea prin intermediul mediilor colaborative: chat, blog, wiki sau forum.

Din punct de vedere computațional, această transformare este obținută în urma aplicării transformării în valori proprii singulare (Singular-Value Decomposition - SVD) similară cu metoda celor mai mici pătrate. Pentru calculul efectiv al transformării se folosesc metode numerice optimizate pe matrici rare.

Pentru îmbunătățirea rezultatelor obținute prin intermediul LSA, matricea inițială este ponderată folosind Tf-Idf (frecvența termenilor invers proporțională cu frecvența documentelor: „term frequency – inverse document frequency”). Astfel ponderea finală este obținută din doi factori:

- frecvența cuvintelor normalizată la numărul aparițiilor cuvântului în document;
- Inversul frecvenței cuvântului în toate documentele (cuvintele rare primesc o bonificație prin intermediul acestei ponderi, pe când cuvinte des întâlnite își pierd din importanță).

Ponderea finală este obținută după următoarea formulă:

$$w_{D,i} = (1 + \ln(tf_{D,i})) \times \ln \frac{N}{n_i}, \quad (5)$$

unde $tf_{D,i}$ reprezintă numărul de apariții ale termenului i în document D , N este numărul total de documente din corpusul folosit pentru învățare și n_i este numărul de documente în care termenul i este prezent.

3.2. Procesul de învățare

Scopul procesului de învățare este de a obține un spațiu în care termenii sunt grupați după concepte și în care se poate estima eficient și cu un grad cât mai ridicat de încredere corelarea/similaritatea dintre aceștia.

Spre deosebire de metodele convenționale de învățare dintr-un corpus de documente, sistemul dezvoltat folosește cuvinte identificate în replicile din chat-uri după prelucrarea acestora și sinonimele acestora („synsets”) obținute din WordNet (<http://wordnet.princeton.edu>), o bază de date lexicală în care cuvintele sunt grupate în seturi de synsets, fiecare reprezentând un concept distinct.

Synset-urile sunt interconectate prin intermediul unor relații lexicale și conceptual-semantice, sporind astfel utilitatea WordNet-ului ca bază de cunoștințe în vederea prelucrării limbajului natural.

Utilizarea WordNet-ului este justificată datorită numărului restrâns de cuvinte dintr-un chat, asigurând astfel îmbogățirea domeniului semantic al termenului respectiv.

Astfel, în vederea învățării supervizate se pornește de la o colecție de chat-uri și se îmbogățește conținutul semantic folosind relațiile lexicale din WordNet. În cadrul procesului urmează aplicarea Tf-Idf, descompunerea efectivă SVD și proiecția pentru gruparea termenilor în jurul a k concepte.

În cadrul procesului de învățare există doi pași:

1. Indexarea cuvintelor:
 - Eliminarea cuvintelor frecvente și irelevante din punctul de vedere al contextului precum „the”, „a”, „an”, „to” etc., din cadrul fiecărei replici;
 - Corectarea morfologică, extragerea rădăcinii și din nou corectare morfologică;
 - Îmbogățirea domeniului lexical folosind synsets din WordNet – relațiile luate în considerare sunt sinonime, hiponime și hipernime, fiecare cu o pondere predefinită;
 - Includerea acestor cuvinte în lista de cuvinte;
 - Determinarea numărului total de documente (în această etapă un document este format din toate replicile unui participant din cadrul unei conversații) drept suma numărului de participanți din toate chat-urile din cadrul corpusului de învățare; în funcție de numărul mediu de replici devine posibilă ajustarea ferestrei de dimensiune fixă pentru segmentarea ulterioară a replicilor aferente unui singur participant.
2. Procesul propriu-zis de învățare:
 - Adăugarea fiecărui document corespunzător tuturor participanților;
 - Aplicare Tf-Idf și transformarea SVD în vederea obținerii descompunerii finale;
 - Reducerea dimensiunii matricei după un k predefinit.

Un aspect important este valoarea lui k în funcție de care LSA aproximează datele, pornind de la un rang inițial mare până la o valoare care reduce considerabil dimensiunea spațiului, asigurând totodată erori cât mai mici. Această valoare este aleasă empiric în intervalul 100-300, pe baza măsurărilor experimentale.

În vederea creșterii performanțelor sistemului, prelucrarea paralelă a fost introdusă atât în cadrul indexării/învățării prin aplicarea paradigmei „Replicated Worker”, dar va fi ulterior integrată și în calculul efectiv al transformării SVD prin modificarea algoritmului Lanczos. Impactul major se reflectă la nivelul indexării prin prelucrarea concomitentă a mai multor chat-uri – independența dintre acestea permite paralelizarea. În partea de descompunere SVD, optimizarea se realizează la nivel de segmentare a matricii (pe linii) și repartitia prelucrărilor aferente pe câte un fir de execuție.

4. Evaluarea sistemului

Ponderea fiecărui factor în determinarea notei finale a unui participant este predefinită în cazul unei analize automate. Modulul de evaluare a corpusului analizează performanțele și corectitudinea sistemului ChAMP prin compararea rezultatelor obținute automat și cele ale adnotatorilor umani.

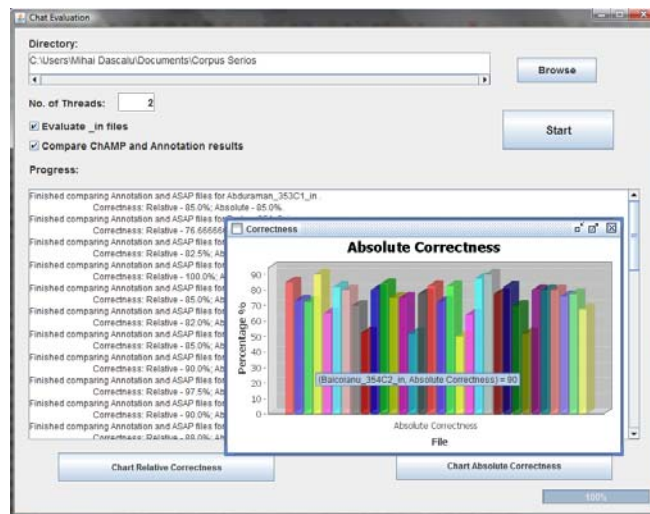


Figura 9. Interfața modulului de evaluare a întregului corpus / a corectitudinii sistemului

Calculul este paralelizat folosind schema „Replicated Workers” care distribuie fiecare chat și prelucrările aferente lui câte unui fir de execuție definit în cadrul interfeței principale.

Doi factori au fost luați în considerare: corectitudinea relativă și cea absolută, raportate la notele individuale ale participanților pentru fiecare chat care reprezintă distanțele euclidiene între nota manuală și scorul automată.

În urma evaluării întregului corpus, rezultatele obținute sunt promițătoare: aproximativ 85% corectitudine relativă și 75% corectitudine absolută.

Noi considerăm că prin ajustări fine ale ponderilor fiecărui factor, învățare LSA cu un grad mai ridicat de supervizare și un număr extins de metrici ale rețelelor sociale (incluzând aici *betweenness*) rezultatele se vor îmbunătăți. Indiferent de rezultatele obținute, componenta subiectivă a evaluării manuale nu poate fi eliminată.

5. Concluzii

Primele rezultate obținute prin aplicarea metricilor specifice rețelelor sociale și analiza semantică a conținutului fiecărei replici din cadrul unei conversații ne permit să tragem concluzia că evaluarea contribuției fiecărui participant într-un mediu colaborativ poate fi realizată automat.

Îmbunătățiri ulterioare ale sistemului includ:

- Generarea unei rețele sociale extinse pe baza tuturor chat-urilor din corpus (nu doar la nivel de conversație izolată);
- Segmentarea semantică a conținutului unui chat;
- Definirea de șabloane, determinarea și marcarea actelor de vorbire în scopul identificării legăturilor implicite;
- Definirea unui profil psihologic al fiecărui participant pe baza informațiilor identificate
- Folosirea indexării inverse pentru determinarea celui mai competent participant la nivelul întregului corpus pe o temă definită printr-un set de cuvinte cheie.

Referințe

Cormen, T., Leiserson, C., Rivest, R., Stein, C., *“Introduction to Algorithms”*, MIT Press 2001.

- Holmer, T., Kienle, A. & Wessner, M. “*Explicit Referencing in Learning Chats: Needs and Acceptance*”, in Nejd, W., Tochtermann, K., (eds.), “*Innovative Approaches for Learning and Knowledge Sharing*”, First European Conference on Technology Enhanced Learning, EC-TEL 2006, Lecture Notes in Computer Science, 4227, Springer, pp. 170-184.
- Manning, C., Schutze, H. , “*Foundations of Statistical Natural Language Processing*”, MIT Press: Cambridge Mass, 1999.
- Dascălu, M., Chioașcă, E.V., Trăușan-Matu, St. „*ASAP – An Advanced System for assessing chat participants*”, in D. Dochev, M. Pistore, and P. Traverso (Eds.): AIMSA 2008, LNAI 5253, Springer, 2008, pp. 58–68.
- Stahl, G., Group Cognition, “*Computer Support for Building Collaborative Knowledge*”, MIT Press, 2006.
- Thomas K Landauer, Peter W. Foltz, Darrell Laham, “*An Introduction to Latent Semantic Analysis*”, Discourse Processes, 25, 259-284, University of Colorado, 1998.
- Trăușan-Matu, S., Chiru, C., Bogdan, R., “*Identificarea actelor de vorbire în dialogurile purtate pe chat*”, în Ștefan Trăușan-Matu, Costin Pribeanu (Eds.), Interacțiune Om-Calculator 2004, Editura Printech, București, pp. 206-214.
- Trăușan-Matu, S., Rebedea, T. (2009). Polyphonic Inter-Animation of Voices in VMT, in Stahl.G. (Ed.), *Studying Virtual Math Teams* (pp. 451 - 473). Boston, MA: Springer US. Vezi și <http://www.ischool.drexel.edu/faculty/gerry/vmt/book/24.pdf>, descărcată în noiembrie 2009.
- Trăușan-Matu, S., Stahl, G., Sarmiento, J., “*Supporting Polyphonic Collaborative Learning*”, E-service Journal, vol. 6, nr. 1, Indiana University Press, pp. 58-74, 2007.
- Juan Dee WEE, Chee-Kit LOOI “*Model for Analysing Collaborative Knowledge Construction in a Quasi-Synchronous Chat Environment*”, Chat Analysis in Virtual Math Teams Workshop at CSCL 2007 conference , Rutgers University, New Brunswick, NJ, USA <http://www.cis.drexel.edu/faculty/gerry/vmtwiki/chee-kit.pdf>, descărcată în 13 noiembrie 2009