Metamodel organizacije za višeagentne sustave velikih razmjera
Plan istraživanja

BOGDAN OKREŠA ĐURIĆ
dokresa@foi.hr

Laboratorij za umjetnu inteligenciju, Fakultet organizacije i informatike
Sveučilište u Zagrebu, Varaždin, Hrvatska

30. ožujka 2016.

Sažetak

Glavni cilj ovog istraživanja je pojednostavnjen pristup organizacijskom modeliranju višeagentnih sustava velikih razmjera. Metode koje opisano istraživanje uključuje, a koje pomažu postizanju zadanog cilja, su: projektiranje ontologija (eng. *ontology engineering*, metamodeliranje i generiranje programskog kôda. Alat za modeliranje koji je predviđeni rezultat ovog istraživanja trebao bi pomoći u razvoju višeagentnih sustava velikih razmjera u brojnim aplikativnim domenama.

Ključne riječi: organizacijsko modeliranje, višegentni sustavi velikih razmjera, ontologija, metamodeliranje

Sadržaj

1 Uvod i motivacija za istraživanje **1**
1.1 Prethodna istraživanja 2

2 Osnovne postavke istaživanja **4**
2.1 Ciljevi istraživanja 4
2.2 Istraživačka pitanja 4

3 Preliminarni rezultati **5**

4 Metodologija **5**
4.1 Izrada ontologije 5
4.2 Metamodel 6
4.3 Procjena vrijednosti metamodela 7

5 Očekivani doprinos **7**

1 Uvod i motivacija za istraživanje

Svojim razvojem kroz povijest čovječanstva [47, 23] organizacija se u smislu "usklađivanja većeg broja ljudi da bi bili uspješniji" [47] postavila kao osnovno sredstvo kojim se nastoji savladati ograničenja individualnih agenata (ljudskih ili softverskih) [34] te iskoristiti njihovu moć suradnje i različitost kako bi zajedno postigli zadane organizacijske ciljeve, tj. ciljeve grupe. Višeagentni sustav (VAS) sastoji se od većeg broja individualnih autonomnih softverskih agenata, čije ponašanje može biti ograničeno određenim skupom pravila, tj. organizirano. Takvi se agenti u svom sustavu nalaze unutar određene okoline na koju mogu utjecati svojim aktuatorima ili iz koje mogu dobivati podražaje korištenjem senzora [29]. Osim s okolinom u kojoj se nalaze, agenti mogu percipirati druge agente koji se nalaze u okolini istog sustava, što postavlja temelje za njihovu međusobnu komunikaciju, suradnju i organizaciju. Shodno tome, stilizirana arhitektura jednostavnog individualnog agenta prikazana je na slici 1.

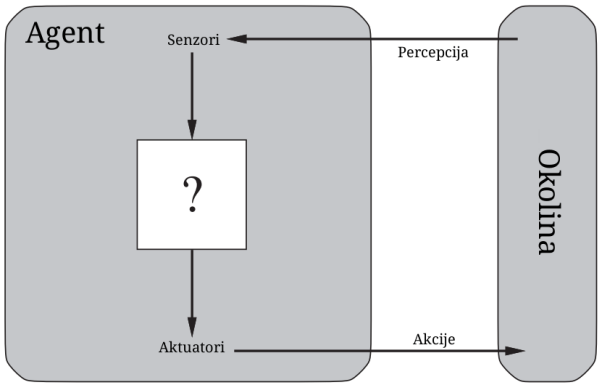

Slika 1: Stilizirani prikaz arhitekture agenta, prema [29]

Istraživanje organizacije agenata te višeagentnih sustava, a posebice višeagentnih sustava velikih razmjera, motivirano je proučavanjem aplikacijskih domena VAS te uočavanjem mjesta za napredak u domeni organizacijskih modela za modeliranje organizacije u VAS velikih razmjera. Prostor za nadogradnju postojećih istraživanja najbolje je uočljiv u proučavanju VAS velikih razmjera te njihovih organizacijskih modela. Naime, nova istraživanja koja se bave organizacijom VAS [3, 1, 2, 24, 30, 32, 34] postavljaju nove standarde za VAS organizacijske modele koji su primjereniji za moderni svijet u kojem raste popularnost tzv. Interneta svega i Interneta stvari, a koji uvjetuje rad u sve kompleksnijoj i turbulentnijoj okolini. Internet svega (eng. *Internet of Everything*, IoE) [34, 6] i Internet stvari (eng. *Internet of Things*, IoT) obuhvaćaju razne objekte, ljude, podatke i procese koji ostvaruju komunikaciju i međusobnu interakciju stvarajući sadržajno bogatiju okolinu, nova iskustva i do sad nedostižne prilike. Primjena IoE i IoT obuhvaća [44, 39, 40, 31] pametnu infrastrukturu, pametne gradove, kuće, itd. Prirodno je Internet svega, pa tako i Internet stvari, predstavljati agentima zbog temeljnih pretpostavki uspješnog djelovanja takvih sustava koji obuhvaćaju desetke ili stotine tisuća (ili čak milijune!) individualnih agenata. Te pretpostavke predviđaju inteligentne sustave koji odgovaraju konceptima distribuiranih i autonomnih sustava - obilježja distribuiranosti, autonomnosti i inteligentnosti jasno opisuju višeagentne sustave. Računajući na navedenu količinu agenata unutar danog sustava neizbježno je govoriti o VAS velikih razmjera.

[30] argumentira potrebu za sveobuhvatnijim pogledom na organizacijsko modeliranje VAS velikih razmjera uvođenjem sedam perspektiva organizacije kompleksnih sustava: organi-

zacijska struktura (tok informacija i odlučivanja unutar organizacije), organizacijska kultura (nefizički elementi organizacije poput znanja, normi, jezika i slično), strategija (dugoročni ciljevi organizacije, planovi za njihovo postizanje te načini mjerenja uspjeha), procesi (aktivnosti organizacije), individualni agenti (osnovne pokretačke jedinice organizacije), organizacijska dinamika (organizacijske promjene i reorganizacija) te kontekst i aspekti međuorganizacije (organizacijsko ponašanje prema okolini). Interensantna novina koju uvodi [30] je i rekurzivno definiranje osnovnih organizacijskih koncepata, čime se postavljaju temelji za modeliranje VAS organizacije u mnogobrojnim razinama, što odgovara VAS velikih razmjera.

Nastavak na motivaciju provođenja ovog istraživanja je i nužan preduvjet za stvaranje organizacijskog metamodela, koji svoje izvore vuče iz ontologije koja obuhvaća sve organizacijske koncepte relevantne za organiziranje VAS velikih razmjera. Stvaranje takve ontologije prilika je za skupljanje znanja o organizaciji VAS te nastavak na nedavno objavljeno istraživanje [30] koje je provedeno u sklopu aktivnosti Laboratorija za umjetnu inteligenciju Fakulteta organizacije i informatike.

1.1 Prethodna istraživanja

Unatoč specifičnosti poput projektiranja ontologije te stvaranja organizacijskog metamodela, interdisciplinarnost vidljiva u isprepletenosti područja informacijskih znanosti (višeagentni sustavi velikih razmjera [43, 40, 38, 34, 30, 30, 27, 20]) s ekonomskim disciplinama (modeliranje organizacije [47, 46, 26, 23, 28]), povezuje ovo istraživanje s mnogim objavljenim istraživanjima.

Povećana kompleksnost i raširenost višeagentnih sustava te njihova uloga u životu modernog čovjeka dovela je do potrebe za proučavanjem organizacije u takvim sustavima, a s ciljem korištenja brojnosti agenata, njihove suradnje prema zajedničkom cilju, rješavanje prepreka vidljivih u ograničenosti individualnih agenata [3, 4, 14, 36, 22]. Pojam organizacije se temeljno promatra iz dvije perspektive: kao entitet ili kao proces, no ne nužno međusobno isključivo [14, 9].

Sukladno tome, dva su osnovna odnosa prema organizaciji u proučavanju VAS [3]: višeagentni sustavi usredotočeni na agenta (eng. *agent-centered multi-agent system*, ACMAS), i višeagentni sustavi usredotočeni na organizaciju (eng. *organization-centered multi-agent system*, OCMAS). ACMAS se vodi idejom da ne postoji organizacija koja je nametnuta sustavu, već individualni agenti svojim djelovanjem, postupcima i ponašanjem utječu na svoju okolinu te organizacija nastaje temeljem interakcije svakog individualnog agenta s njegovom okolinom. Ovakav pogled na VAS podsjeća na mrave ili roj insekata, no ne predstavlja zadovoljavajuću podlogu za kompleksnije sustave (npr. potencijalno otežava usklađivanje agenata prema zajedničkom cilju) [3, 12, 41]. S druge strane, OCMAS organizaciju promatra u smislu strukture sustava koja je nametnuta agentima. Agenti su upoznati s organizacijom, no mogu je mijenjati ukoliko je potrebna prilagodba sustava nestabilnoj okolini. Takvi sustavi mogu imati jasno određen tok informacija i određivanja, kao i komunikacijski protokol, što ga čini podobnijim za kompleksnije sustave. Upravo je sinteza obaju pogleda pogodna za moderne sustave koji djeluju u visoko turbulentnoj okolini [28, 7, 13], kako bi se spojile dobrobiti oba načina organizacije VAS.

VAS organizacijski modeli služe za prikaz arhitekture organizacije agenata, a izražavaju se jezicima za modeliranje sastavljenim od specifičnih simbola. Uobičajeno je da jezik za modeliranje ima dva osnovna elementa [18, 19, 5]: konceptualizaciju (skup koncepata za

modeliranje) i sintaksu (pravila za povezivanje elemenata konceptualizacije). Prema tome, model [8] je instanciranje sintaktički iskazane koceptualizacije koja opisuje dani sustav. Jezik za modeliranje opisan je metamodelom, tj. modelom modela. Specifična vrsta metamodela je domenska ontologija [18] - konceptualizacija dane domene bez obzira na jezičnu sintaksu.

Organizacijski modeli procjenjuju se temeljem skupa dimenzija identificiranih za vrijeme istraživanja VAS. Modeli navedeni u tablici 1 opisani su temeljem osam dimenzija iz [8], gdje su dimenzije 1-4 osnovne, a 5-8 dodatne:

1. organizacijska struktura - nepromjenjivi elementi strukture organizacije agenata;
2. organizacijske funkcije - ciljevi organizacije agenata;
3. organizacijska interakcija - vremenska ovisnost standardiziranih akcija i interakcije elemenata organizacije;
4. organizacijske norme - dodatno upravljanje povezanošću strukture, interakcije i funkcija organizacije;
5. organizacijska procjena - mjere performansi organizacije s obzirom na ciljeve;
6. organizacijska evolucija - promjena organizacije prema poticaju iz okoline;
7. organizacijska okolina - okruženje na koje mogu djelovati agenti;
8. organizacijske ontologije - jedinstveno znanje agenata o aplikacijskoj domeni organizacije.

Tablica 1: Modeli i dimenzije kojima pripadaju njihovi odgovarajući koncepti, prilagođeno iz [8]

Model	Dimenzija							
	Struktura	Interakcija	Funkcija	Norme	Okolina	Evolucija	Evaluacija	Ontologija
AGR	+	+						
TAEMS			+		+		+	
MOISE+	+		+	+		+		
ISLANDER	+	+		+				+
OperA	+	+	+	+				+
AGRE	+	+			+			
MOISE	+		+	+		+		
ODML	+						+	
STEAM	+		+					
AUML	+	+	+		+			
MAS-ML	+	+	+	+	+			

Novije istraživanje postavlja skup od sedam perspektiva organizacijske arhitekture [34, 30] namijenjenih specifično za VAS velikih razmjera:

- organizacijska struktura - tok informacija i odlučivanja unutar organizacije;
- organizacijska kultura - nefizički elementi organizacije poput znanja, normi, jezika i slično;
- strategija - dugoročni ciljevi organizacije, planovi za njihovo postizanje te načini mjerenja uspjeha;

- procesi - aktivnosti organizacije;
- individualni agenti - osnovne pokretačke jedinice organizacije;
- organizacijska dinamika - organizacijske promjene i reorganizacija;
- kontekst i međuorganizacijski aspekti - organizacijsko ponašanje prema okolini.

Osim navedenog, moderna istraživanja [24, 1] konačno uvode temporalno-dinamičnu komponentu organizacije u organizacijske modele argumentirajući modele za VAS u realnom vremenu i promovirajući reorganizaciju VAS. Dinamična reorganizacija i pojavna samoorganizacija koncepti su kojima se teži u modeliranju VAS koji su spremni za uspješno djelovanje u nestalnom i neizvjesnom okruženju.

2 Osnovne postavke istaživanja

Ovo istraživanje izravno se nadograđuje na istraživanja o VAS velikih razmjera [3, 30, 34], s ciljem definiranja sveobuhvatne ontologije organizacijskih koncepata te stvaranja metamodela temeljenog na spomenutoj ontologiji i gore navedenih sedam perspektiva organizacijskog modeliranja.

2.1 Ciljevi istraživanja

Shodno navedenom općem cilju ovog istraživanja, identificirana su tri specifična cilja istraživanja:

C1 Definirati iscrpnu ontologiju koja će obuhvatiti koncepte organizacijskog modeliranja i koncepte višeagentnih sustava velikih razmjera.

C2 Izraditi sveobuhvatan organizacijski metamodel temeljen na definiranoj ontologiji.

C3 Razviti alat za modeliranje u svrhu generiranja temelja (tj. kostura) višeagentnog sustava velikih razmjera koji je konzistentan s navedenim principima organizacijskog modeliranja.

Navedeni ciljevi i njihovo ispunjenje pogone ovo istraživanje te je temeljem istih određen metodološki put istraživanja. Posebnost ovog istraživanja sažeta je u gornjim ciljevima u iscrpnosti ontologije i sveobuhvatnosti metamodela, što je u skladu s idejom nadogradnje na postojeća istraživanja [3, 30, 34, 32].

2.2 Istraživačka pitanja

Temeljem postavljenih ciljeva istraživanja identificirana su sljedeća istraživačka pitanja:

P1 Koji su organizacijski koncepti značajni i odgovarajući za organizacijsko modeliranje višeagentnih sustava velikih razmjera? Koji od takvih koncepata bi trebali biti uključeni u ontologiju ili metamodel u sklopu ovog istraživanja?

P2 Kojim će scenarijima za višeagentne sustave iz stvarnog života biti usmjeren razvijani alat za modeliranje?

P3 Kako se nose višeagentni sustavi velikih razmjera, modelirani prema raznim organizacijskim modelima uključenima u izrađenom metamodelu, međusobno i u usporedbi sa stvarnim agentima?

Identificirana istraživačka pitanja odgovaraju mavedenim ciljevima istraživanja te služe dodatnom usmjeravanju tijeka istraživanja.

3 Preliminarni rezultati

U sklopu aktivnosti ModelMMORPG[1] projekta, autor ovog istraživanja proveo je neke aktivnosti koje predstavljaju preliminarne rezultate i svojevrsne ulazne parametre za ovo istraživanje: analizirani su prikupljeni rezultati stvarnih agenata (igrača) koji su sudjelovali u jednoj instanci VAS aplikacijske domene (*The Mana World* mrežna računalna igra s ulogama namijenjena većem broju igrača) [33], zatim je u sklopu projekta u tijeku razvoj autonomnog agenta, te je u razvoju ontologija organizacijskih koncepata (prihvaćen rad u postupku objave), a identificirane su i inicijalne metode modeliranja agenata za mrežne računalne igre namijenjene većem broju igrača (eng. *massively multi-plyer online game*, MMOG) [35].

4 Metodologija

Planirano istraživanje jasno je podijeljeno u tri elementa: ontologija, metamodel, i procjena. Ključan rezultat je dobro definirana iscrpna organizacijska ontologija, s obzirom da se na njoj temelji organizacijski metamodel, zbog čega je bitno odabrati dobru metodologiju za inženjering ontologija.

4.1 Izrada ontologije

Kao što je navedeno, ontologija je ključan element ovog istraživanja. Kandidat za metodologiju za definiranje ontologije identificiran je u METHONTOLOGY [17], dobro strukturiranoj metodologiji namjenjenoj izgradnji ontologije.

METHONTOLOGY valja provesti u ukupno šest koraka:

1. Specifikacija - rezultira specifikacijskim dokumentom zapisanim prirodnim jezikom. Namjena ove ontologije je okupljanje i obuhvaćanje organizacijskih koncepata relevantnih za organizacijsko modeliranje VAS velikih razmjera. Iscrpnost ontologije potrebna je za kasnije korake istraživanja u kojima će biti odabrani najbitniji identificirani elementi. Ontologija će biti filtrirana do koncepata koji su ključni za izgradnju organizacijskog metamodela. Ontologija će, u sklopu aktivnosti ModelMMORPG projekta biti javno objavljena. Koncepti ontologije bit će zapisani korištenjem OWL (eng. *Web Ontology Language* jezika u OWL/XML serijalizaciji. Ovaj korak zahtijeva usklađenost s ciljem istraživanja C1 - iscrpnošću ontologije.
2. Akvizicija znanja - korak koji se provodi usporedno sa definiranjem specifikacije, nezavisna je aktivnost koja gubi intenzitet s napredovanjem procesa definiranja ontologije, ali ovisi o cilju istraživanja C1. Glavni izvor korišten u ovom istraživanju objavljen je u [32, 30] u sklopu OOVASIS[2] projekta Laboratorija za umjetnu inteligenciju Fakulteta organizacije i informatike.
3. Konceptualizacija - izrada pojmovnika te grupiranje i opisivanje identificiranih pojmova.

[1] Za više detalja posjetite `http://ai.foi.hr/modelmmorpg`
[2] Za više detalja posjetite `http://ai.foi.hr/oovasis`

4. Integracija - povezivanje s metaontologijama i drugim ontologijama, koliko je to moguće i smisleno.
5. Implementacija - odabir i implementacija ontologije u odabranom alatu. Ontologija će većinom biti definirana korištenjem Protégé[3] alata.
6. Evaluacija - tehnička procjena ontologije, zajedno s njenom softverskom okolinom i dokumentacijom, u odnosu na referentnu stavku, koja može biti dokumentacija proizašla iz prvog koraka. Evaluacija podrazumijeva i verifikaciju (tehnički proces koji osigurava korektnost ontologije, njene softverske okoline i dokumentacije s referentnom stavkom) i validaciju (osigurava prikladnost ontologije, njene softverske okoline, i dokumentacije sustavu koji predstavljaju) ontologije. U konačnici ovaj korak daje odgovor na jedan dio istraživačkog pitanja P1.

4.2 Metamodel

Znanstvena metoda modeliranja [45] sastoji se od četiri faze: postavljanje zadatka, izbor ili stvaranje modela, istraživanje modela, i prijenos spoznaja s modela na original. Shodno tome, identificirano je nekoliko koraka u postupku izrade organizacijskog metamodela, a koji doprinose ispunjenju cilja istraživanja C2:

1. Određivanje detaljnosti - potrebno je odrediti razinu specifičnosti metamodela te dubinu modeliranih koncepata, tj. razinu apstrakcije promatrane domene. Suviše apstraktni koncepti dovode do neizražajnosti modela, dok prevelika konkretizacija domenskih koncepata stvara potencijalno previše kompleksan model. Obje krajnosti su loše te mogu dovesti do modela otežane primjenjivosti. Dakako, odluke unutar ovog koraka uvelike ovise o istraživačkom pitanju P2.
2. Ocjena i odabir elemenata - analiza ontologije te procjena korisnosti ili iskoristivosti uključenih koncepata. Iscrpna ontologija organizacijskih koncepata primjenjivih na VAS velikih razmjera potencijalno obuhvaća koncepte koji nisu prilagođeni uključivanju u metamodel ili su dovoljno neutjecajni na konačni ishod da mogu biti isključeni iz finalne verzije metamodela. Rezultat ovog koraka je popis koncepata odabranih za uključivanje u modelirani metamodel, koji predstavlja dio odgovora na istraživačko pitanje P1.
3. Usporedba i informiranje - analiziranje, procjena i usporedba postojećih VAS organizacijskih modela i njihovih koncepata [42, 16, 10, 25, 21, 15, 11, 37, 1]. Cilj je uočiti dobre primjere koji odgovaraju krajnjem cilju ovog istraživanja te ih prilagoditi za razvijani metamodel.
4. Stvaranje metamodela - usporedba koncepata odabranih u 3. koraku i onih uočenih u 4. koraku te njihovo spajanje. Slijedi uključivanje odabranih koncepata u metamodel pomoću odabranog alata (npr. AToM[3] [4]), što ispunjava pretpostavke cilja istraživanja C3.
5. Usporedba sa sedam perspektiva i evaluacija modela - usporedba modeliranog modela i njegovih instanci s ranije navedenih sedam perspektiva organizacijskog modeliranja. U slučaju da model ne zadovoljava obilježja organizacijskog modeliranja iznesenih u [30], potrebno je ponoviti slijed od koraka 4. ili 2.

[3] Za više detalja posjetite `http://protege.stanford.edu/`
[4] Za više detalja posjetite `http://atom3.cs.mcgill.ca/`

4.3 Procjena vrijednosti metamodela

Organizacijski model dobiven tijekom ovog istraživanja bit će procijenjen korištenjem testnih scenarija razvijenih korištenjem *The Mana World*, mrežne računalne igre s ulogama namijenjene većem broju igrača (eng. *massively multi-player online role-playing game*, MMORPG). MMORPG igre odabrane su za okolinu testnog scenarija kao jedan od odličnih primjera primjene VAS velikih razmjera.

Navedeni način procjene vrijednosti metamodela odgovorit će na istraživačko pitanje P3 te ispuniti cilj istraživanja C3, a u skladu s tvrdnjom "*Zato se vrijednost modela neće procjenjivati po sveukupnoj sličnosti sa stvarnošću, već po mogućnosti ostvarenja ciljeva istraživanja.*" [45] potvrditi i vrijednost modeliranog metamodela.

5 Očekivani doprinos

Ovo istraživanje nadograđuje se na recentna istraživanja koja se bave organizacijom u VAS velikih razmjera [3, 30, 34], u kojima je uočen prostor za napredak. Organizacija VAS interesantan je koncept za istraživanje, između ostalog, i zbog sve češćeg povezivanja pojma višeagentnih sustava s konceptima Interneta stvari i Interneta svega kojima popularnost iznimno brzo raste.

Ovim istraživanjem razvijaju se temelji za lakše modeliranje VAS, s naglaskom na VAS velikih razmjera. Razvojem ili nadogradnjom alata kojim je moguće dobiti kostur za razvoj VAS koji odgovara unaprijed zadanim značajkama organizacijskog modeliranja te uspostaviti model razvijanog VAS naglašava se praktična primjenjivost rezultata ovog istraživanja. Nadalje, definiranjem ontologije i razvojem metamodela jasno je vidljiv znanstveni doprinos ovog istraživanja.

Kao što neka od citiranih djela ostavljaju otvorenim pitanja vezana uz organizacijske aspekte modeliranja VAS, ili ih tek postavljaju, tako će i ovo istraživanje otvoriti mogućnosti za daljnje istraživanje teme te njeno širenje - npr. proširenje ili prilagođavanje razvijenog metamodela specifičnim, drugačijim ili detaljnijim potrebama.

Literatura

[1] H. A. Abbas. Realizing the noshape mas organizational model:. *International Journal of Agent Technologies and Systems*, 7(2):75–104, 4 2015.

[2] H. A. Abbas and S. Shaheen. Mos-2: A two-dimension space for positioning mas organizational models. 11 2015.

[3] H. A. Abbas, S. I. Shaheen, and M. H. Amin. Organization of multi-agent systems: An overview. *International Journal of Intelligent Information Systems*, 4(3):46–57, 2015.

[4] E. Argente, J. Palanca, G. Aranda, V. Julian, V. Botti, A. Garcia-Fornes, and A. Espinosa. Supporting agent organizations. In H.-D. Burkhard, G. Lindemann, R. Verbrugge, and L. Z. Varga, editors, *Multi-Agent Systems and Applications V*, chapter Supporting, pages 236–245. Springer Berlin Heidelberg, 2007.

[5] S. Assar. Meta-modeling: concepts, tools and applications, 2015.

[6] L. Atzori, A. Iera, and G. Morabito. The internet of things: A survey. *Computer Networks*, 54(15):2787–2805, 10 2010.

[7] D. D. Corkill and S. E. Lander. Diversity in agent organizations. *Object Magazine*, 8(4):41–47, 1998.

[8] L. R. Coutinho, J. S. Sichman, and O. Boissier. Modelling dimensions for agent organizations. In V. Dignum, editor, *Handbook of Research on Multi-Agent Systems*, pages 18–50. IGI Global, 2009.

[9] T. De Wolf. Emergence and self-organisation: a statement of similarities and differences. *Proc. of the 2nd Int. Workshop on Engineering Self*, pages 96–110, 2004.

[10] K. S. Decker. Tæms : A framework for environment centered analysis & design of coordination mechanisms. In *Foundations of Distributed Artificial Intelligence*, chapter 16, pages 429–448. John Wiley & Sons, Inc, 1996.

[11] V. Dignum. *A model for organizational interaction: based on agents, founded in logic*. PhD thesis, 2004.

[12] V. Dignum. *Handbook of Research on Multi-Agent Systems: Semantics and Dynamics of Organizational Models*, volume 12. IGI Global, 2009.

[13] V. Dignum. The role of organization in agent systems. In V. Dignum, editor, *Handbook of Research on Multi-Agent Systems*, pages 1–16. IGI Global, 1 2009.

[14] V. Dignum and F. Dignum. A landscape of agent systems for the real world. Technical report, 2006.

[15] M. Esteva, J. Padget, and C. Sierra. Formalizing a language for institutions and norms. chapter Formalizin, pages 348–366. Springer Berlin Heidelberg, 2002.

[16] J. Ferber, O. Gutknecht, and F. Michel. From agents to organisations: an organizational view of multi-agent systems. *Agent-Oriented Software Engineering (AOSE) IV*, (July 2003):214–230, 2004.

[17] M. Fernández-López, A. Gómez-Pérez, and N. Juristo. Methontology: From ontological art towards ontological engineering. *AAAI-97 Spring Symposium Series*, SS-97-06:33–40, 1997.

[18] G. Guizzardi. On ontology, ontologies, conceptualizations, modeling languages, and (meta)models. In *Proceedings of the 2007 Conference on Databases and Information Systems IV: Selected Papers from the Seventh International Baltic Conference DB&IS'2006*, pages 18–39. IOS Press, 2007.

[19] B. Henderson-Sellers. *On the Mathematics of Modelling, Metamodelling, Ontologies and Modelling Languages*. SpringerBriefs in Computer Science. Springer Berlin Heidelberg, 2012.

[20] B. Horling and V. Lesser. Quantitative organizational models for large-scale agent systems. In T. Ishida, L. Gasser, and H. Nakashima, editors, *Massively Multi-Agent Systems I*, chapter Quantitati, pages 121–135. Springer Berlin Heidelberg, 2005.

[21] J. F. Hübner, J. S. Sichman, and O. Boissier. A model for the structural, functional, and deontic specification of organizations in multiagent systems. In G. Bittencourt and G. L. Ramalho, editors, *Advances in Artificial Intelligence*, pages 118–128. Springer Berlin Heidelberg, 2002.

[22] J. F. Hübner, L. Vercouter, and O. Boissier. Instrumenting multi-agent organisations with artifacts to support reputation processes. In J. F. Hübner, E. Matson, O. Boissier, and

V. Dignum, editors, *Coordination, Organizations, Institutions and Norms in Agent Systems IV*, chapter Instrument, pages 96–110. Springer Berlin Heidelberg, 2009.

[23] S. Kapustić, D. Radošević, and M. Žugaj. Uvođenje organizacijske znanosti u klasifikaciji znanstvenih oblasti i područja. In *Zbornik radova*, pages 9–10. Fakultet organizacije i informatike, 1986.

[24] M. A. Laouadi, F. Mokhati, and H. Seridi. A novel organizational model for real time mas: Towards a formal specification. In L. Chen, S. Kapoor, and R. Bhatia, editors, *Intelligent Systems for Science and Information*, pages 171–180. Springer International Publishing, 2014.

[25] V. Lesser, K. Decker, T. Wagner, N. Carver, A. Garvey, B. Horling, D. Neiman, R. Podorozhny, M. N. Prasad, A. Raja, R. Vincent, P. Xuan, and X. Q. Zhang. Evolution of the gpgp/tæms domain-independent coordination framework. *Autonomous Agents and Multi-Agent Systems*, 9(1/2):87–143, 7 2004.

[26] D. Nadler. *Organizational architecture : designs for changing organizations*. Jossey-Bass, 1 edition, 1992.

[27] J. J. Odell, H. Dyke Parunak, and M. Fleischer. Software engineering for large-scale multi-agent systems: Research issues and practical applications. chapter The Role o, pages 27–38. Springer Berlin Heidelberg, 2003.

[28] R. B. Posey and M. Haire. Modern organization theory. *Administrative Science Quarterly*, 5(4):609–611, 3 1961.

[29] S. J. Russell and P. Norvig. *Artificial Intelligence: A Modern Approach*. Prentice Hall series in artificial intelligence. Pearson Education, Inc., 3rd edition, 2010.

[30] M. Schatten. Organizational architectures for large-scale multi-agent systems' development: An initial ontology. *Advances in Intelligent Systems and Computing*, 290:261–268, 2014.

[31] M. Schatten. Smart residential buildings as learning agent organizations in the internet of things. *Business Systems Research*, 5(1):34–46, 2014.

[32] M. Schatten, P. Grd, M. Konecki, and R. Kudelić. Towards a formal conceptualization of organizational design techniques for large scale multi agent systems. *Procedia Technology*, 15:577–586, 2014.

[33] M. Schatten and B. Okreša Đurić. A social network analysis of a massively multi-player on-line role playing game. In B. Kang, editor, *Proceedings of the 4th International Conference on Modeling and Simulation*, pages 37–42. IEEE, 2015.

[34] M. Schatten, J. Ševa, and I. Tomičić. A roadmap for scalable agent organizations in the internet of everything. *Journal of Systems and Software*, 115:31–41, 2016.

[35] M. Schatten, I. Tomicic, and B. Okreša Đurić. Multi-agent modeling methods for massivley multi-player on-line role-playing games. In P. Biljanović, editor, *38th International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO)*, pages 1256–1261. IEEE, 5 2015.

[36] E. L. Van Den Broek, C. M. Jonker, A. Sharpanskykh, J. Treur, et al. Formal modeling and analysis of organizations. In O. Boissier, J. Padget, V. Dignum, G. Lindemann, E. Matson, S. Ossowski, J. S. Sichman, and J. Vázquez-Salceda, editors, *Coordination, Organizations,*

Institutions, and Norms in Multi-Agent Systems, pages 18–34. Springer Berlin Heidelberg, 2006.

[37] H. Van Dyke Parunak and J. Odell. Representing social structures in uml. In *Proceedings of the fifth international conference on Autonomous agents - AGENTS '01*, pages 100–101. ACM Press, 2001.

[38] O. Vermesan, P. Friess, P. Guillemin, S. Gusmeroli, H. Sundmaeker, A. Bassi, I. S. Jubert, M. Mazura, M. Harrison, M. Eisenhauer, P. Doody, F. Peter, G. Patrick, G. Sergio, B. Harald, Sundmaeker Alessandro, J. Ignacio Soler, M. Margaretha, H. Mark, E. Markus, and D. Pat. Internet of things strategic research roadmap. In O. Vermesan, P. Friess, P. Guillemin, S. Gusmeroli, H. Sundmaeker, A. Bassi, and I. S. Jubert, editors, *Internet of Things Strategic Research Roadmap*, pages 9–52. 2009.

[39] P. Vlacheas, R. Giaffreda, V. Stavroulaki, D. Kelaidonis, V. Foteinos, G. Poulios, P. Demestichas, A. Somov, A. Biswas, and K. Moessner. Enabling smart cities through a cognitive management framework for the internet of things. *IEEE Communications Magazine*, 51(6):102–111, 6 2013.

[40] E. Welbourne, L. Battle, G. Cole, K. Gould, K. Rector, S. Raymer, and M. Balazinska. Building the internet of things using rfid. *Internet Computing, IEEE*, 13(3):48 – 55, 2009.

[41] D. Weyns, R. Haesevoets, and A. Helleboogh. The macodo organization model for context-driven dynamic agent organizations. *ACM Transactions on Autonomous and Adaptive Systems*, 5(4):1–29, 11 2010.

[42] D. Weyns, R. Haesevoets, A. Helleboogh, T. Holvoet, and W. Joosen. The macodo middleware for context-driven dynamic agent organizations. *ACM Transactions on Autonomous and Adaptive Systems*, 5(1):1–28, 2 2010.

[43] N. Wijngaards, B. Overeinder, M. van Steen, and F. Brazier. Supporting internet-scale multi-agent systems. *Data & Knowledge Engineering*, 41(2-3):229–245, 6 2002.

[44] M. Yun and B. Yuxin. Research on the architecture and key technology of internet of things (iot) applied on smart grid. In *2010 International Conference on Advances in Energy Engineering*, pages 69–72. IEEE, 6 2010.

[45] M. Žugaj. *Znanstvena istraživanja u društvenim znanostima i nastanak znanstvenog djela*. Tonimir, 2007.

[46] M. Žugaj and M. Schatten. *Arhitektura suvremenih organizacija*. Tonimir i Fakultet organizacije i informatike, 2005.

[47] M. Žugaj, J. Šehanović, and M. Cingula. *Organizacija*. TIVA Tiskara Varaždin, 2nd edition, 2004.