

Oznaka poročila: ARRS_ZV_RPROJ_ZP_2008/170

ZAKLJUČNO POROČILO O REZULTATIH RAZISKOVALNEGA PROJEKTA

A. PODATKI O RAZISKOVALNEM PROJEKTU

1. Osnovni podatki o raziskovalnem projektu

Šifra projekta	Z2-9684
Naslov projekta	Inteligentno usmerjanje in razvrščanje v sistemih GRID (iGRIDras)
Vodja projekta	21305 Daniel Vladušič
Tip projekta	Za Podoktorski projekt - aplikativni
Obseg raziskovalnih ur	2.550
Cenovni razred	B
Trajanje projekta	01.2007 - 12.2008
Nosilna raziskovalna organizacija	2012 XLAB razvoj programske opreme in svetovanje d.o.o.
Raziskovalne organizacije - soizvajalke	
Družbeno-ekonomski cilj	11 Neusmerjene raziskave (temeljne)

2. Sofinancerji¹

1.	Naziv	XLAB d.o.o.
	Naslov	Pot za Brdom 100 SI-1000 Ljubljana, Slovenija
2.	Naziv	
	Naslov	
3.	Naziv	
	Naslov	

B. REZULTATI IN DOSEŽKI RAZISKOVALNEGA PROJEKTA

3. Poročilo o realizaciji programa raziskovalnega projekta²

Raziskovalna hipoteza projekta je bila, da je moč z uporabo metod strojnega učenja izboljšati delovanje usmerjanja in razvrščanja opravil v sistemih GRID. Vkolikor so bili na začetku projekta v uporabi več ali manj algoritmi, ki so razvrščali opravila po računskih enotah zgolj na podlagi statičnih pravil, ki so stanje sistema upoštevala zgolj v manjši meri ali pa sploh ne, se je to tokom trajanja projekta spremenilo. V zadnjem času je prišlo do bolj množične uporabe metod umetne inteligence na tem področju, kjer izpostavljamo predvsem algoritem ALEA – dejstvo lahko uporabimo za sklep, da je usmerjanje in razvrščanje opravil v zadnjem času postalo še bolj pereč problem. Po drugi strani se je v času trajanja projekta opravil tudi premik z arhitekture GRID v arhitekturo SOA. Sama arhitektura GRID namreč ni v dovolj veliki meri

omogočala t.i., sklepanja pogodb med uporabniki in ponudnikom zmogljivosti. V arhitekturi SOA so tovrstne pogodbe na prvem mestu (SLA), zato so sistemi GRID dejansko postali samo ponudniki zmogljivosti – servis. Vidimo torej, da se je celotna infrastruktura ugotavljanja ciljnih zmogljivosti, glede na potrebe opravila, premaknila en nivo višje. V sistemih GRID se torej odločamo več ali manj zgolj na podlagi zmogljivosti, ki so trenutno na voljo (niso rezervirane, njihove lastnosti pa so v skladu z zahtevanimi).

V našem projektu smo torej osredotočeni predvsem na usmerjanje in razvrščanje opravil na nivoju arhitekture GRID, pri čemer predpostavljamo, da so zahtevane lastnosti zmogljivosti zadovoljene (npr., zahtevani operacijski sistem, ipd). Druga predpostavka, ki smo jo upoštevali, je princip črne škatle (t.i., black-box approach). Cilj te predpostavke je, da se upravitelj sistema GRID ne ukvarja z nastavitvami algoritma, temveč zgolj doda naš algoritem, oz., vstavek in nadaljuje z delom. Pri tem izhajamo tudi iz težavnosti in cene prilagajanja že obstoječih sistemov GRID, saj uporaba generičnega vstavka praktično ne zahteva prilagajanja obstoječe programske opreme. V skladu s programom projekta smo se osredotočili na uporabo že znanih metod strojnega učenja, pri čemer želeli uporabiti tudi že znane programske pakete (t.i., off-the-shelf software).

Pri izbiri metod strojnega učenja smo se omejili na najbolj znane: naivni Bayes, lokalno utežena regresija (LWR) ter odločitvena drevesa (J48). Vse metode so implementirane v prosto dostopnem paketu WEKA. Za ta paket smo se odločili predvsem zaradi jezika, v katerem je implementiran (java), saj je večina programskih paketov za simulacijo sistemov GRID napisana ravno v tem jeziku.

Glede na izbrani princip črne škatle smo izbrane metode strojnega učenja ovili v štirikratno prečno preverjanje, kjer smo spreminjali nastavitve algoritma. Izbor najboljših nastavitve je temeljil na meri AROC (površina pod ROC krivuljo). Le-to smo izbrali zato, ker je bil naš predikcijski problem binaren in neuravnotežen – imeli smo veliko število uspešnih primerov – v katerih se mera AROC obnaša bolje kot običajna mera natančnosti predikcije (ang., classification accuracy). Glede na neuravnoteženost problema smo dodali še zunanje štirikratno prečno preverjanje, kjer smo spreminjali utež manjšinskega razreda, ter pri različnih utežeh izvajali prej opisano prečno preverjanje. Namen tako širokega iskanja je bil predvsem zagotoviti, da se algoritem lahko v večini primerov uporablja kot črna škatla, oz., da se upravitelj sistema ne ukvarja z nastavitvami algoritma.

Opisi opravil so bili sestavljeni iz naslednjih atributov: ocena časa, ki je potreben za izvedbo opravila, rok izvedbe opravila, dolžina vrste pri računalniku, ki bo opravilo izvedel, oznaka računalnika, na katerega smo dali opravilo v izvajanje ter na koncu še uspešnost izvedbe opravila, glede na postavljeni rok izvedbe opravila. Vidimo, da je opis pravila minimalen oz., zelo generičen, kar zagotavlja splošnost in uporabnost algoritma in rezultatov naših eksperimentov.

Glede na to, da smo opisali osnovno postavitev in značilnosti našega algoritma, ki uporablja metode strojnega učenja, se zdaj osredotočimo na osnovno postavitev sistema, implementiranih algoritmov razvrščanja in usmerjanja ter napovedovanje.

Arhitektura našega testnega sistema je vsebovala sprejemno vozlišče, ki je bilo odgovorno za sprejemanje opravil, ki so prišla v sistem ter izhodno vozlišče, kjer so se združevala opravila, oz., rezultati opravljenih opravil. Računske zmogljivosti so vsebovale svojo čakalno vrsto ter procesor, na katerem se je opravilo izvajalo. Opravila so bila med seboj neodvisna.

Osnovni algoritmi (tako smo jih poimenovali zato, ker naša metoda popravlja oz., spremeni procesor, kamor osnovni algoritem pošlje opravilo), ki smo jih uporabili so naključno usmerjanje opravil, round-robin ter prvi-prosti. Naključno usmerjanje opravil smo v naše eksperimentalno delo vključili predvsem zato, ker se mnogokrat izkaže, da tovrstni preprosti algoritmi delujejo izjemno dobro. Dodatno pojasnilo potrebuje še zadnji algoritem. Pri prvi-prosti smo implementirali naslednjo strategijo: naključno smo izbrali začetno vozlišče ter preverili, če je le-to prosto. Vkolikor ni bilo, smo nadaljevali po round-robin principu, ter pri vsakem od vozlišč, vkolikor ni bilo prosto, zabeležili dolžino čakalne vrste. Če smo prišli nazaj do začetnega vozlišča, smo opravilo usmerili v vozlišče z najkrajšo vrsto.

V drugem delu našega eksperimentalnega dela, smo eksperimentirali z algoritmom ALEA oz., našim dodatkom v ogrodju algoritma ALEA. Samega algoritma na tem mestu ne bomo opisovali, povejmo le, da smo iz originalnega algoritma odstranili pomembno lastnost, ki smo jo nadomestili z našim algoritmom. Sam algoritem ALEA namreč preverja, če so spremembe, ki jih je naredil s svojo hevristično oceno, dobre ali slabe, medtem ko naša modifikacija tega ne upošteva. Poleg tega pri eksperimentalnem delu z algoritmom ALEA nismo uporabljali osnovnih algoritmov, saj smo se zanašali le na napovedno moč našega algoritma. Ti dejstvi kažeta, da je bil naš raziskovalni fokus usmerjen predvsem v oceno moči strojnega učenja, ki so vpete v osnovno ogrodje algoritma ALEA.

Pojasnimo še, kako smo se odločali, ali bomo sploh spreminjali odločitev osnovnega algoritma. Vsako opravilo je osnovni algoritem že usmeril v določeno vozlišče – to smo poimenovali osnovno vozlišče. Z našim algoritmom smo ocenili verjetnost uspešne izvedbe v osnovnem

vozlšču ter jo primerjali z napovedanimi ocenami uspešne izvedbe v drugih vozlščih. Vkolikor je obstajalo vozlšče, ki je imelo višjo verjetnost te ocene, smo spremenili ciljno vozlšče, sicer pa smo pustili osnovnega. Tovrstna previdnost je bila potrebna tudi zato, ker smo razvijali generičen algoritem, kjer ne poznamo lastnosti, kvalitet in morebitnih slabosti osnovnega algoritma.

Posvetimo se eksperimentom in rezultatom obeh raziskovalnih sklopov. V prvem sklopu smo izvedli primerjava s preprostimi metodami usmerjanja in razvrščanja. Primere opravil smo generirali na dva načina: generirali smo večje število opravil, ki so bila po času urejena tako, da ni prihajalo do zasičenj sistema. Z izvajanjem takšnih opravil smo se najprej, z vsako od metod, naučili lastnosti sistema (hitrosti procesorjev, zanesljivosti vozlšča, ipd). Nato smo generirali še več množic opravil, ki pa so bila urejena tako, da je bila verjetnost zasičenja sistema zelo velika. Sam sistem (število procesorjev, njihova hitrost, ipd) se ni spreminjal. Nato smo izvedli večje število eksperimentov z vsako od metod strojnega učenja, ki je uporabljala različne osnovne algoritme. Pri tem smo merili zamudo vsakega od opravil. Vkolikor je bilo opravilo izvedeno v roku, je bilo izvedeno uspešno, sicer smo izvajanje opravila označili kot neuspešno.

Izvedli smo tudi eksperiment, kjer smo med delovanjem popolnoma spremenili lastnosti sistema – ohranili smo število procesorjev, vendar smo njihove lastnosti nadomestili s popolnoma drugačnimi. Prav tako smo izvedli eksperiment, kjer so posamezna vozlšča oz., procesorji med delovanjem algoritma delno ali pa popolnoma prenehali z delovanjem. Rezultate tega sklopa lahko strnemo v nekaj ugotovitev: uporaba dodatnega algoritma z metodami strojnega učenja v večini primerov izboljša delovanje osnovnega algoritma, kar smo tudi pričakovali ter tako potrdili našo raziskovalno hipotezo. Po drugi strani smo bili presenečeni nad hitrostjo prilagajanja spremembam, ki so bile v sistemu umetno ustvarjene. Naša metoda se je namreč hitro prilagodila npr. izpadlemu vozlšču, tako da nanj skorajda ni več pošiljala opravil. Po drugi strani, ko se je to vozlšče spet pojavilo v sistemu, se je ravno zaradi teh redkih opravil, ki jih je metoda pošiljala tja, spet pričelo uporabljati v večji meri. Najhujši test metode je bila popolna sprememba lastnosti sistema, ki pa jo je metoda dobro prestala, saj se je hitro prilagodila novemu stanju. Omenimo še primerjavo med izbranimi metodami strojnega učenja: pričakovali smo, da bo lokalno utežena regresija dala najboljše rezultate, kar se je tudi potrdilo. Drugi dve metodi pri tovrstni uporabi nista bili dovolj robustni, zato je bila njuna uspešnost mešana. Kljub vsemu ocenjujemo, da se pri tovrstnih problemih takšen dodatek z metodami strojnega učenja izplača, saj z njim praktično ne izgubimo pri hitrosti usmerjanja opravil.

V drugem raziskovalnem sklopu smo merili povprečno zamudo opravil (ang., average tardiness). Našo metodo smo vpeli v ogrodje ALEA, ki smo ga modificirali v skladu z opisom, navedenim v prejšnjih odstavkih. Pri tem pristopu se nismo več osredotočali na posamezne primere, saj smo izjemno povečali število eksperimentov, tako da smo dobili stabilna povprečja.

Bistveni rezultati tega raziskovalnega sklopa so, da je, tudi brez osnovnega algoritma, ki bi dajal osnovno usmeritev opravila v vozlšča, naša metoda dovolj močna, da se zelo približa, oz., celo doseže rezultate trenutno najboljšega algoritma za usmerjanje in razvrščanje opravil v sistemih GRID. Preizkusili smo obe različici testnih algoritmov v ogrodju ALEA: EDD (ang., Earliest Deadline First) ter ERD (ang., Earliest Release Date First). Naša metoda se je, z uporabo odločitvenih dreves (J48) po manjšem številu eksperimentov popolnoma izenačila z metodo EDD ter jo mestoma celo izboljšala. Kljub vsemu pa s takšnimi nastavitvami nismo uspeli doseči metode ERD, temveč smo se ji zgolj približali. Izjemno pomembno je tudi dejstvo, da sta obe metodi imeli enako nastavljene lastnosti ogrodja, pri čemer so originalne testne metode izkoriščale prej omenjene prednosti originalnega ALEA pristopa.

V tem sklopu moramo omeniti še očitno slabost t.i., off-the-shelf pristopa. Izkazalo se je, da v tovrstnih eksperimentih, kjer je velikost učne množice velika, določenih metod ni moč več uporabljati. Pri nas smo imeli težave z lokalno uteženo regresijo, ki je sčasoma, ko je velikost učne množice rastla, preprosto prenehala delovati. Za uporabo v realnem sistemu bi torej morali izbrati boljšo implementacijo lokalno utežene regresije, ki se je v prvem raziskovalnem sklopu izkazala kot zelo dober algoritem za tovrstne probleme.

Naše raziskovalno delo je torej potrdilo raziskovalno hipotezo, postavljeno na začetku projekta. Zaradi razvoja področja, smo se po eni strani omejili s količino atributov, ki jih uporabljamo pri učenju in se bolj posvetili razvoju generičnega vstavka za splošen problem usmerjanja in razvrščanja v sistemih GRID (z minimalnim naborom atributov), po drugi pa smo sledili razvoju področja in opravili eksperimente z enim trenutno najboljših pristopov.

Poročilo zaključujemo še s faktografskim pregledom opravljenega dela. Raziskovalni projekt je zaključen s sklopom DS-6 (objavljena 2 konferenčna članka ter 1 izvirni znanstveni članek v reviji). Za evaluacijo našega dela (sklop DS-2) smo izbrali dve merili – število opravil, ki so zaključena v roku ter povprečno zakasnitev postavljenega roka (t.i., tardiness). Pri tem smo uporabili enak nabor algoritmov strojnega učenja (sklop DS-3): lokalno utežena regresija,

naivni Bayes ter regresijska drevesa. Pri eksperimentalnem delu (sklop DS-4) smo izbrane algoritme, kot vtičnik, dodali v dve simulacijski ogradi: PeerSim ter GridSim, kar je omogočilo uporabo dveh različnih pristopov k delu. V ogradi PeerSim je bilo moč preveriti obnašanje vtičnika v vsakem posamičnem primeru, medtem ko je ograda GridSim omogočila testiranje na večjem številu eksperimentov. Primerjava med preprostimi algoritmi (naključno, round-robin ter prvi-prosti) ter algoritmi strojnega učenja je pokazala, da se slednji obnašajo bolje (dosežejo večje število pravočasno izvršenih opravil). Pri tem se tudi dobro naučijo lastnosti samega sistema, ki je uporabljen, saj na hitrejša vozlišča pošiljajo večje število opravil. Po drugi strani se ti algoritmi tudi hitro prilagodijo novim situacijam – pokazali smo, da se tudi v primeru popolne zamenjave strojne opreme (hitrosti vozlišč) algoritmi hitro prilagodijo in delujejo bolje od preprostih. V ogradi GridSim smo kot primerjalni algoritem izbrali algoritem ALEA, ki s pomočjo tabu iskanja dosega zelo dobre rezultate. Primerjava je pokazala, da se algoritmi strojnega učenja izenačijo ali pa zelo dobro približajo algoritmu ALEA. Pri primerjavah je potrebno poudariti, da smo v vseh primerih izvajali eksperimente po principu črne škatle – algoritmi strojnega učenja so torej imeli na voljo večje število parametrov, ki so jih interno uporabljali za prečno preverjanje. Prav tako smo uporabili minimalen nabor atributov (v primeru ALEA smo izpustili enega najpomembnejših atributov), saj smo želeli doseči popolno neodvisnost od implementacije ter predvsem splošnost. Rezultati torej kažejo, da je moč z zelo omejenim naborom atributov ter s pristopom črne škatle pridobiti rezultate, ki so vsaj primerljivi trenutno najboljšim algoritmom razvrščanja poslov v sistemih GRID.

4. Ocena stopnje realizacije zastavljenih raziskovalnih ciljev³

Potrdili smo pravilnost raziskovalne hipoteze - uporaba algoritmov strojnega učenja pri razvrščanju in usmerjanju izboljša lastnosti usmerjanja in razvrščanja osnovnih algoritmov. V skladu s programom dela smo opravili eksperimentalno delo, v katerem smo primerjali kvaliteto popravljanja osnovnega algoritma. Pri tem smo preverili tudi moč prilagajanja v primeru sprememb v sistemu. V obeh primerih se izkazalo, da osnovni algoritmi, ki so bili v teh primerih dokaj enostavni, svoje delo opravljajo dokaj dobro, a jih je moč, z uporabo našega pristopa, dodatno izboljšati. Pomembno je dejstvo, da ob spremembah sistema (npr., sprememba lastnosti vozlišča), naš algoritem za popravljanje odločitev to zelo hitro zazna in se prilagodi. V tem sklopu smo se osredotočili tudi na oceno posamičnih primerov, kjer smo ugotovili, da v določenih primerih naš pristop, kljub vsemu deluje slabše od originalnega, kar je bilo tudi pričakovano. V skladu z razvojem področja smo opravili tudi primerjavo z najboljšimi algoritmi usmerjanja opravil po vozliščih sistema (primerjava z algoritmom ALEA). Tukaj smo se osredotočili na primerjavo pristopov pri velikem številu opravil oz., na primerjavo povprečnih rezultatov. Pokazali smo, da se z uporabo našega pristopa da približati, oz., v omejenem obsegu, tudi doseči rezultate najboljših algoritmov. Naš pristop je v obeh primerjavah upošteval samo minimalen nabor učnih atributov, poleg tega pa smo v primeru ALEA odstranili enega zelo pomembnih atributov. V primeru ALEA smo uporabili zgolj shemo dela – odstranili smo informacijo o osnovnem vozlišču, kamor opravilo razvrsti algoritem ALEA ter tudi povratno informacijo o kvaliteti premika opravila. Kljub vsemu, se je uporaba strojnega učenja po principu črne škatle izenačila z EDD različico algoritma ALEA, medtem ko se je ERD različica približala. Naše raziskovalne cilje smo z dvema tipoma izvedenih eksperimentov zadovoljili – v obeh primerih smo uporabili enako ogrado za algoritme strojnega učenja. Prav tako smo preverili delovanje pristopa z dvema različnima meriloma, z dvema različnima pristopoma ocenjevanja. V primerjavi s kompleksnim algoritmom razvrščanja, smo našemu pristopu dovolili samo uporabo najbolj osnovnih atributov ter osnovne informacije. Na podlagi rezultatov sklepamo, da se v primeru investicije v prilagoditev, ki je manjša kot reimplementacija algoritma za razvrščanje opravil v sistemih GRID, za posamičen sistem, naš sistem obnaša zelo dobro. Pri tem poudarjamo, da smo pokazali tako dobro delovanje v posamičnih primerih (eksperimentalno delo v ogradi PeerSim) kot tudi dobro delovanje v povprečju (eksperimentalno delo v ogradi GridSim).

5. Utemeljitev morebitnih sprememb programa raziskovalnega projekta⁴

Ni sprememb.

6. Najpomembnejši znanstveni rezultati projektne skupine⁵

Znanstveni rezultat

1.	Naslov	SLO	Vzporedni algoritem z razvrščevalnikom bremena za problem najmanjši k-center in podobne probleme
		ANG	Load-balanced parallel solver for the minimum k-center and related problems
	Opis	SLO	Predstavili smo vzporedni algoritem za reševanje problema najmanjši k-center. Za doseganje uravnoteženja bremena pri računanju na več-procesorskem sistemu predstavimo in ocenimo kvaliteto rešitev, ki jih dobimo pri uporabi novega algoritma za razvrščanje bremena. Nov algoritem generira množico vseh k kombinacij izmed n stvari brez ponavljanja. S simulacijo pokažemo tudi, da je moč razviti algoritem uporabiti na rahlo sklopljenih sistemih (GRID), kjer za simulacijo skrbi adaptiven razvrščevalnik bremena z uporabo metod strojnega učenja.
		ANG	A load-balanced exact solver for computing the exact solutions of minimum k-center is described. To achieve the load balance on a dedicated multiprocessor system a new algorithm for parallel generation of a set of all k-combinations without repetitions is introduced and analysed. We demonstrate that the new algorithm can also be used in a resource competitive environment if used or supplemented with a simple adaptive job scheduler. The solver is tested by producing the benchmarks for the minimum k-center problem.
	Objavljeno v		ČERNIVEC, Aleš, VLADUŠIČ, Daniel, SLIVNIK, Boštjan. Load-balanced parallel solver for the minimum k-center and related problems. V: HAMZA, Mohamed H. (ur.). Proceedings of the IASTED International Conference on Parallel and Distributed Computing and Networks, February 16-18, 2009, Innsbruck, Austria : a publication of the International Association of Science and Technology for Development. Anaheim; Calgary; Zurich: Acta Press, cop. 2009, str. 133-138
	Tipologija		1.08 Objavljeni znanstveni prispevek na konferenci
	COBISS.SI-ID		6954836
2.	Naslov	SLO	Izboljševanje razvrščanja opravil v okoljih GRID z uporabo preprostih metod strojnega učenja
		ANG	Improving Job Scheduling in GRID Environments with Use of Simple Machine Learning Methods
	Opis	SLO	Predstavili smo poskus izboljšanja razvrščanja opravil v heterogenem okolju GRID z uporabo metod strojnega učenja. Naš cilj je izdelava vtičnika za obstoječe sisteme GRID, s katerim se izognemo dragim in zamudnim modifikacijami teh sistemov. Predpostavljamo, da osnovni algoritem v sistemih ne bomo zavrgli temveč zgolj popravljamo njegove odločitve, če obstaja možnost, da je naš izbor vozlišča boljši. Osredotočamo se na uporabo obstoječih metod strojnega učenja, ki so uporabljeni po načelu črne škatle. Rezultati kažejo, da se s tovrstnim pristopom da izboljšati obstoječe algoritme razvrščanja.
		ANG	We present an attempt to improve job scheduling over heterogeneous GRID nodes by employing machine learning methods. Our aim is to provide a plugin which can be easily added to existing frameworks, thus avoiding significant modifications. We assume that existing scheduling algorithm in the framework should not be completely overridden, but rather modified only if there are chances that the modification will yield a better result. We focus on use of off-the-shelf machine learning methods in a black-box manner. The results show that improvements over the simple scheduling algorithms can be made.
	Objavljeno v		Sprejeto v objavo: Daniel Vladušič, Aleš Černivec and Boštjan Slivnik. 6th International Conference on Information Technology : New Generations ITNG 2009 April 27-29, 2009, Las Vegas, Nevada, USA
	Tipologija		1.08 Objavljeni znanstveni prispevek na konferenci
3.	COBISS.SI-ID		0000000
	Naslov	SLO	Uporaba načela črne škatle z metodami strojnega učenja z namenom izboljšanja razvrščanja opravil v okoljih GRID
		ANG	Using the black-box approach with machine learning methods in order to improve job scheduling in GRID environments
	Opis	SLO	Članek se osredotoča na iskanje povezave med opravili in zmogljivostmi v sistemu z uporabo metod strojnega učenja. Predstavili smo dva eksperimenta, ki sta konstruirana s ciljem doseči zasičenje sistema. V prvem metode strojnega učenja popravljajo odločitve osnovnega algoritma

			vsebovanega v sistemu, v drugem pa delujejo samostojno. Rezultati kažejo, da je moč s takšnim pristopom preseči rezultate določenih metod, ali pa se jim vsaj zelo približati.
		ANG	This article focuses on mapping jobs to resources with use of off-the-shelf machine learning methods. In the article we focus on two sets of experiments, both constructed with a goal of congesting the system. In the first part, the machine learning methods are used as assistants for the base resource selection algorithms, while in the second part, they are used to directly select the resource for job execution. The results show that even with a such black-box approach of the off-the-shelf machine learning methods, we can achieve improvements or at least get comparable results.
	Objavljeno v		Sprejeto v objavo: Daniel Vladušič. WSEAS TRANSACTIONS ON SYSTEMS AND CONTROL
	Tipologija		1.01 Izvirni znanstveni članek
	COBISS.SI-ID		0000000
4.	Naslov	SLO	
		ANG	
	Opis	SLO	
		ANG	
	Objavljeno v		
	Tipologija		
	COBISS.SI-ID		
5.	Naslov	SLO	
		ANG	
	Opis	SLO	
		ANG	
	Objavljeno v		
	Tipologija		
	COBISS.SI-ID		

7. Najpomembnejši družbeno-ekonomsko relevantni rezultati projektne skupine⁶

Družbeno-ekonomsko relevantni rezultat			
1.	Naslov	SLO	Upravljanje virtualnih organizacij v XtreamOS-u: Pregled
		ANG	Virtual Organization Management in XtreamOS: An Overview
	Opis	SLO	Projekt XtreamOS se ukvarja z uvajanjem neposredne podpore virtualnim organizacijam (VO) neposredno v jedro modificiranega operacijskega sistema Linux. Cilj projekta je torej zmanjšati oz., odpraviti režijske stroške, ki nastanejo z uporabo povezovalne programske opreme z vpeljavo VO podpore neposredno v jedro operacijskega sistema. V tem članku predstavljamo vizijo VO-jev in opišemo različne vidike upravljanja VO-jev (s stališča arhitekture, upravljanja izvajanja aplikacij, ipd), ki sledijo iz uporabniških zahtev. Te zahteve smo uporabili v fazi definicije zahtev projekta iGRIDras.
		ANG	The XtreamOS project promotes native Virtual Organization (VO) support in the Linux-based operating system for the next generation GRIDs, reason being the recognition of the fundamental role of VOs in GRIDs. The aim of the XtreamOS project is to minimize or even omit the overhead brought by layers of existing GRID middleware by enabling the native VO support. This paper presents the XtreamOS vision of VOs in GRID and describes various aspects of VO management (from architecture, security to application execution). These requirements were used in the requirements phase of the iGRIDras project.
	Šifra		B.03 Referat na mednarodni znanstveni konferenci
	Objavljeno v		YANG, Erica Y., VLADUŠIČ, Daniel. Towards next generation grids : proceedings of the CoreGRID Symposium 2007, August 27-28, Rennes, France. New York: Springer, cop. 2007, 75-84.

2.	Tipologija		1.08 Objavljeni znanstveni prispevek na konferenci
	COBISS.SI-ID		21164839
	Naslov	SLO	Simulacijsko ogrodje projekta iGRIDras, izvedeno iz ogrodij PeerSim ter GridSim
		ANG	The iGRIDras simulation framework based on PeerSim and GridSim frameworks.
	Opis	SLO	Simulacijsko ogrodje projekta iGRIDras teče v poljubnem okolju z Java6. Omogoča simulacijo inteligentnega razvrščanja v sistemih GRID s pomočjo ogrodij PeerSim ter GridSim. V ogrodje je vključen vtičnik, ki omogoča avtomatsko učenje usmerjanja in razvrščanja neodvisnih opravil na zmogljivosti, ki so definirane v sistemu. Prav tako ogrodje omogoča primerjavo med različnimi preprostimi algoritmi usmerjanja in razvrščanje ter pristopom iGRIDras. Možna je tudi primerjava z algoritmom ALEA. Vnos v COBISS je v teku.
		ANG	The simulation framework of the iGRIDras project supports arbitrary operating system capable of running Java6. It enables simulation of the intelligent routing and scheduling in GRID systems through PeerSim and GridSim frameworks. The framework encapsulates a plug-in, capable of automatic learning of routing and scheduling of independent jobs to resources defined in the system. The framework also supports comparisons between various algorithms and the iGRIDras approach.
	Šifra		F.08 Razvoj in izdelava prototipa
	Objavljeno v		Daniel Vladušič. Programska koda se hrani v podjetju XLAB.
	Tipologija		2.21 Programska oprema
	COBISS.SI-ID		22567463
3.	Naslov	SLO	
		ANG	
	Opis	SLO	
		ANG	
	Šifra		
	Objavljeno v		
	Tipologija		
	COBISS.SI-ID		
4.	Naslov	SLO	
		ANG	
	Opis	SLO	
		ANG	
	Šifra		
	Objavljeno v		
	Tipologija		
	COBISS.SI-ID		
5.	Naslov	SLO	
		ANG	
	Opis	SLO	
		ANG	
	Šifra		
	Objavljeno v		
	Tipologija		
	COBISS.SI-ID		

8. Pomen raziskovalnih rezultatov projektne skupine⁷

8.1. Pomen za razvoj znanosti⁸

SLO

Rezultat aplikativnega projekta iGRIDras prinaša uporabo metod umetne inteligence v sisteme GRID na nivoju razvrščanja in usmerjanja. Od tovrstnih že znanih pristopov se projekt iGRIDras loči predvsem po izbranih metodah in načelu njihove uporabe – v projektu iGRIDras so vse metode uporabljene po principu črne škatle z namenom implementacije vtičnika, za katerega skrbniku sistema GRID ne bo potrebno nastavljati nobenih parametrov. Bistvenega pomena je torej obdelava problema usmerjanja in razvrščanja z zgoraj omenjenim pristopom ter rezultati, ki kažejo smiselnost in uporabnost pristopa.

V projektu smo pokazali uporabnost metod umetne inteligence pri problemu usmerjanja in razvrščanja v sistemih GRID, pri čemer smo se osredotočali predvsem na praktične vidike uporabe v smislu nezahtevnosti za administratorja sistema. Pri tem je potrebno poudariti hoteno generičnost, ki je bila uporabljena v projektu (v smislu minimalnega nabora atributov, ipd), s katero smo dosegli dobre rezultate. Sklepamo lahko, da je moč z dodatnim prilagajanjem izbranemu sistemu doseči še bistveno boljše rezultate, a je preizkus te teze izven ciljev projekta iGRIDras.

Razvito ogrodje projekta iGRIDras gradi na prosto dostopnih ogrodjih PeerSim ter GridSim, kar zagotavlja pokritje bistvenih ogrodij s področja ter kot takšno omogoča hitre modifikacije, ki se bodo skozi čas pojavile zaradi novejših različic prej omenjenih ogrodij. V tem smislu ogrodje projekta iGRIDras predstavlja trdno osnovo za nadaljnje raziskave na tem področju.

ANG

The results of the applicative project iGRIDras enable the use of the artificial intelligence methods in the GRID systems on the level of scheduling and routing. Despite such use of the artificial intelligence and machine learning methods is already known, the benefit of the iGRIDras project is in the machine learning methods used and the way they were used. Namely, within iGRIDras project the machine learning were used in the black-box manner, leaving the GRID administrator no parameters to modify or tune. The crucial result of the project is thus the research of the routing and scheduling problem with the aforementioned approach along with results which show the benefits of such approach.

The project has shown the applicability of the artificial intelligence methods to the routing and scheduling problem in the GRID systems where we focused mainly on practical use in the sense of simple use for the system administrator. We emphasize that the approach was intentionally generic (e.g., minimum set of attributes used) which already yielded good results. We can conclude that tailoring of the approach to the target system should yield even better results. Still, this hypothesis was not confirmed within the iGRIDras project, as it was out of the project's scope.

The developed framework is building on freely available PeerSim and GridSim frameworks, which ensures that the major frameworks from the field are covered in our work. Furthermore, further modifications arising from new versions of the aforementioned frameworks can be easily incorporated. This fact ensures the use of the iGRIDras framework in future developments in the field.

8.2. Pomen za razvoj Slovenije⁹

SLO

Nadaljnji razvoj Republike Slovenije teži zaradi specifičnosti večinoma v raziskave in razvoj. V tem smislu je pridobitev novih znanj v podjetju XLAB, ki so uporabna neposredno v produktih podjetja ter v mednarodnih projektih, v katere je podjetje močno vpeto, izjemnega pomena, saj povečuje konkurenčnost podjetja tako na poslovni kot tudi akademski ravni. Na tem mestu poudarjamo, da je podjetje XLAB zaradi svoje specifične notranje strukture izjemno odvisno od tovrstnih raziskav ter dognanj, ki jih pri tem pridobimo. Podjetje XLAB s svojimi rešitvami na področju sistemov GRID, SOA arhitekture in distribuiranih sistemov nasploh potrebuje rešitev, ki jo je moč enostavno in hitro uporabiti za izboljšave v tovrstnih produktih. V tem smislu bodo dognanja s področja inteligentnega usmerjanja in razvrščanja uporabljena, po določenih prilagoditvah, v hrbtenici družine produktov ISL ter na področju porazdeljevanja bremen lokalnih sistemov, ki so v uporabi v različnih EU projektih (XtreemOS, SLA@SOI, itd.).

ANG

Due to the specificities of Slovenia its future economic development depends mostly on research and development. Acquisition of new knowledge and expertise directly applicable to the XLAB's

products and our many international projects, is thus extremely important, as it improves the company's business competitiveness as well as its academic level. It should be stressed that XLAB's specific internal structure makes it strongly depend on this kind of research and discoveries gained through the research. XLAB urgently needs quickly and easily applicable knowledge to expand the product line in Grid systems, SOA architectures and distributed systems in general. Discoveries in the area of intelligent routing and scheduling will be applied to improve the load balancing strategies in the ISL line of products as well as in various EU projects (XtreemOS, SLA@SOI etc).

9. Samo za aplikativne projekte!

Označite, katerega od navedenih ciljev ste si zastavili pri aplikativnem projektu, katere konkretne rezultate ste dosegli in v kakšni meri so doseženi rezultati uporabljeni

Cilj		
F.01	Pridobitev novih praktičnih znanj, informacij in veščin	
	Zastavljen cilj	☒ DA ☐ NE
	Rezultat	Dosežen
	Uporaba rezultatov	Delno
F.02	Pridobitev novih znanstvenih spoznanj	
	Zastavljen cilj	☒ DA ☐ NE
	Rezultat	Dosežen
	Uporaba rezultatov	V celoti
F.03	Večja usposobljenost raziskovalno-razvojnega osebja	
	Zastavljen cilj	☒ DA ☐ NE
	Rezultat	Dosežen bo v naslednjih 3 letih
	Uporaba rezultatov	Delno
F.04	Dvig tehnološke ravni	
	Zastavljen cilj	☒ DA ☐ NE
	Rezultat	Dosežen bo v naslednjih 3 letih
	Uporaba rezultatov	Uporabljen bo v naslednjih 3 letih
F.05	Sposobnost za začetek novega tehnološkega razvoja	
	Zastavljen cilj	☒ DA ☐ NE
	Rezultat	Dosežen
	Uporaba rezultatov	Delno
F.06	Razvoj novega izdelka	
	Zastavljen cilj	☐ DA ☒ NE
	Rezultat	
	Uporaba rezultatov	
F.07	Izboljšanje obstoječega izdelka	
	Zastavljen cilj	☒ DA ☐ NE
	Rezultat	Dosežen bo v naslednjih 3 letih
	Uporaba rezultatov	Delno

F.08	Razvoj in izdelava prototipa	
	Zastavljen cilj	☒ DA ☐ NE
	Rezultat	Dosežen bo v naslednjih 3 letih
	Uporaba rezultatov	V celoti
F.09	Razvoj novega tehnološkega procesa oz. tehnologije	
	Zastavljen cilj	☐ DA ☒ NE
	Rezultat	
	Uporaba rezultatov	
F.10	Izboljšanje obstoječega tehnološkega procesa oz. tehnologije	
	Zastavljen cilj	☐ DA ☒ NE
	Rezultat	
	Uporaba rezultatov	
F.11	Razvoj nove storitve	
	Zastavljen cilj	☐ DA ☒ NE
	Rezultat	
	Uporaba rezultatov	
F.12	Izboljšanje obstoječe storitve	
	Zastavljen cilj	☒ DA ☐ NE
	Rezultat	Dosežen bo v naslednjih 3 letih
	Uporaba rezultatov	V celoti
F.13	Razvoj novih proizvodnih metod in instrumentov oz. proizvodnih procesov	
	Zastavljen cilj	☐ DA ☒ NE
	Rezultat	
	Uporaba rezultatov	
F.14	Izboljšanje obstoječih proizvodnih metod in instrumentov oz. proizvodnih procesov	
	Zastavljen cilj	☐ DA ☒ NE
	Rezultat	
	Uporaba rezultatov	
F.15	Razvoj novega informacijskega sistema/podatkovnih baz	
	Zastavljen cilj	☒ DA ☐ NE
	Rezultat	Dosežen bo v naslednjih 3 letih
	Uporaba rezultatov	Delno
F.16	Izboljšanje obstoječega informacijskega sistema/podatkovnih baz	
	Zastavljen cilj	☒ DA ☐ NE
	Rezultat	Dosežen
	Uporaba rezultatov	Uporabljen bo v naslednjih 3 letih
F.17	Prenos obstoječih tehnologij, znanj, metod in postopkov v prakso	

	Zastavljen cilj	☒ DA ☐ NE
	Rezultat	Dosežen bo v naslednjih 3 letih
	Uporaba rezultatov	Delno
F.18	Posredovanje novih znanj neposrednim uporabnikom (seminarji, forumi, konference)	
	Zastavljen cilj	☐ DA ☒ NE
	Rezultat	
	Uporaba rezultatov	
F.19	Znanje, ki vodi k ustanovitvi novega podjetja ("spin off")	
	Zastavljen cilj	☐ DA ☒ NE
	Rezultat	
	Uporaba rezultatov	
F.20	Ustanovitev novega podjetja ("spin off")	
	Zastavljen cilj	☐ DA ☒ NE
	Rezultat	
	Uporaba rezultatov	
F.21	Razvoj novih zdravstvenih/diagnostičnih metod/postopkov	
	Zastavljen cilj	☐ DA ☒ NE
	Rezultat	
	Uporaba rezultatov	
F.22	Izboljšanje obstoječih zdravstvenih/diagnostičnih metod/postopkov	
	Zastavljen cilj	☐ DA ☒ NE
	Rezultat	
	Uporaba rezultatov	
F.23	Razvoj novih sistemskih, normativnih, programskih in metodoloških rešitev	
	Zastavljen cilj	☐ DA ☒ NE
	Rezultat	
	Uporaba rezultatov	
F.24	Izboljšanje obstoječih sistemskih, normativnih, programskih in metodoloških rešitev	
	Zastavljen cilj	☐ DA ☒ NE
	Rezultat	
	Uporaba rezultatov	
F.25	Razvoj novih organizacijskih in upravljaljskih rešitev	
	Zastavljen cilj	☐ DA ☒ NE
	Rezultat	
	Uporaba rezultatov	
F.26	Izboljšanje obstoječih organizacijskih in upravljaljskih rešitev	

	Zastavljen cilj	☐ DA ☒ NE
	Rezultat	
	Uporaba rezultatov	
F.27	Prispevek k ohranjanju/varovanje naravne in kulturne dediščine	
	Zastavljen cilj	☐ DA ☒ NE
	Rezultat	
	Uporaba rezultatov	
F.28	Priprava/organizacija razstave	
	Zastavljen cilj	☐ DA ☒ NE
	Rezultat	
	Uporaba rezultatov	
F.29	Prispevek k razvoju nacionalne kulturne identitete	
	Zastavljen cilj	☐ DA ☒ NE
	Rezultat	
	Uporaba rezultatov	
F.30	Strokovna ocena stanja	
	Zastavljen cilj	☐ DA ☒ NE
	Rezultat	
	Uporaba rezultatov	
F.31	Razvoj standardov	
	Zastavljen cilj	☐ DA ☒ NE
	Rezultat	
	Uporaba rezultatov	
F.32	Mednarodni patent	
	Zastavljen cilj	☐ DA ☒ NE
	Rezultat	
	Uporaba rezultatov	
F.33	Patent v Sloveniji	
	Zastavljen cilj	☐ DA ☒ NE
	Rezultat	
	Uporaba rezultatov	
F.34	Svetovalna dejavnost	
	Zastavljen cilj	☐ DA ☒ NE
	Rezultat	
	Uporaba rezultatov	
F.35	Drugo	
	Zastavljen cilj	☐ DA ☒ NE

Zaključno poročilo o rezultatih raziskovalnega projekta

Rezultat	
Uporaba rezultatov	

Komentar

Glede na to, da smo projekt izvajali v gospodarskem subjektu, menimo da je cilj vsakega aplikativnega raziskovalnega projekta pridobiti nova praktična in znanstvena spoznanja, ki smo jih, v okviru projekta, tudi dosegli.

Rezultati projekta bodo uporabljeni na več ravneh, tako v praksi kot tudi v nadaljnjih raziskovalnih projektih, v katere je podjetje XLAB vpeto.

10. Samo za aplikativne projekte!

Označite potencialne vplive oziroma učinke vaših rezultatov na navedena področja

	Vpliv	Ni vpliva	Majhen vpliv	Srednji vpliv	Velik vpliv	
G.01	Razvoj visoko-šolskega izobraževanja					
G.01.01.	Razvoj dodiplomskega izobraževanja	☐	☐	☐	☐	
G.01.02.	Razvoj podiplomskega izobraževanja	☐	☐	☐	☐	
G.01.03.	Drugo:	☐	☐	☐	☐	
G.02	Gospodarski razvoj					
G.02.01	Razširitev ponudbe novih izdelkov/storitev na trgu	☐	☐	☐	☐	
G.02.02.	Širitev obstoječih trgov	☐	☐	☐	☐	
G.02.03.	Znižanje stroškov proizvodnje	☐	☐	☐	☐	
G.02.04.	Zmanjšanje porabe materialov in energije	☐	☐	☐	☐	
G.02.05.	Razširitev področja dejavnosti	☐	☐	☐	☐	
G.02.06.	Večja konkurenčna sposobnost	☐	☐	☐	☐	
G.02.07.	Večji delež izvoza	☐	☐	☐	☐	
G.02.08.	Povečanje dobička	☐	☐	☐	☐	
G.02.09.	Nova delovna mesta	☐	☐	☐	☐	
G.02.10.	Dvig izobrazbene strukture zaposlenih	☐	☐	☐	☐	
G.02.11.	Nov investicijski zagon	☐	☐	☐	☐	
G.02.12.	Drugo:	☐	☐	☐	☐	
G.03	Tehnološki razvoj					
G.03.01.	Tehnološka razširitev/posodobitev dejavnosti	☐	☐	☐	☐	
G.03.02.	Tehnološko prestrukturiranje dejavnosti	☐	☐	☐	☐	
G.03.03.	Uvajanje novih tehnologij	☐	☐	☐	☐	
G.03.04.	Drugo:	☐	☐	☐	☐	
G.04	Družbeni razvoj					

G.04.01.	Dvig kvalitete življenja	☐	☐	☐	☐	
G.04.02.	Izboljšanje vodenja in upravljanja	☐	☐	☐	☐	
G.04.03.	Izboljšanje delovanja administracije in javne uprave	☐	☐	☐	☐	
G.04.04.	Razvoj socialnih dejavnosti	☐	☐	☐	☐	
G.04.05.	Razvoj civilne družbe	☐	☐	☐	☐	
G.04.06.	Drugo:	☐	☐	☐	☐	
G.05.	Ohranjanje in razvoj nacionalne naravne in kulturne dediščine in identitete	☐	☐	☐	☐	
G.06.	Varovanje okolja in trajnostni razvoj	☐	☐	☐	☐	
G.07	Razvoj družbene infrastrukture					
G.07.01.	Informacijsko-komunikacijska infrastruktura	☐	☐	☐	☐	
G.07.02.	Prometna infrastruktura	☐	☐	☐	☐	
G.07.03.	Energetska infrastruktura	☐	☐	☐	☐	
G.07.04.	Drugo:	☐	☐	☐	☐	
G.08.	Varovanje zdravja in razvoj zdravstvenega varstva	☐	☐	☐	☐	
G.09.	Drugo:	☐	☐	☐	☐	

Komentar

Na področju usmerjanja in razvrščanja v sistemih GRID ter večjih tovrstnih sistemih nasploh se v zadnjem času kaže izrazita delitev vlog na iskanje primernih zmogljivosti ter v drugem koraku, primerno usmerjanje in razvrščanje v manjši množici najdenih primernih zmogljivosti. Kljub temu je problem usmerjanja in razvrščanja v tovrstnih sistemih še vedno zelo težaven, pri čemer se število tovrstnih sistemov povečuje. Raziskave na tem področju so torej čedalje bolj intenzivne ter tudi usmerjene v algoritme, ki omogočajo avtomatsko učenje - metode umetne inteligence.

Opisano torej potrjuje da je delo relevantno predvsem za gospodarski in tehnološki razvoj podjetja XLAB ter drugih podjetij, ki se ukvarjajo s tovrstno problematiko.

11. Pomen raziskovanja za sofinancerje, navedene v 2. točki¹⁰

1.	Sofinancer	XLAB d.o.o.		
	Vrednost sofinanciranja za celotno obdobje trajanja projekta je znašala:		12.193,00	EUR
	Odstotek od utemeljenih stroškov projekta:		14,10	%
	Najpomembnejši rezultati raziskovanja za sofinancerja			Šifra
	1.	XLAB se v okviru svojih dejavnosti ukvarja tudi s simulacijami sistemov GRID. Raba teh orodij v okviru projekta je pokazala slabosti, ki so izjemnega pomena pri odločanju za nadaljnjo rabo.		F.01
	2.	Prototip vtičnika za izboljšanje usmerjanja in razvrščanja v sistemih GRID bo moč uporabiti v različnih produktih, saj so raziskovalne in komercialne dejavnosti XLAB-a usmerjene v porazdeljene sisteme		F.08

	3.	S povezovanjem znanj s področja strojnega učenja in porazdeljenih sistemov se v podjetju XLAB ustvarja baza kombiniranih znanj, ki so izjemnega pomena za prepoznavanje novih priložnosti.	F.03
	4.	Z uporabo končnega izdelka, ki bo sledil iz prototipnega vtičnika, bo XLAB izboljšal svoje zmogljivosti interne poslovne komunikacijske hrbtenice, ki je v uporabi v produktni liniji izdelkov ISL.	F.07
	5.	Projekt je podjetju prinesel vpogled v možnosti, ki sledijo iz uporabe metod strojnega učenja na področju usmerjanja in razvrščanja, pri čemer je bistvenega pomena poudarek na uporabnosti raziskave.	F.02
	Komentar	Podjetje XLAB je k sofinanciranju pristopilo predvsem zaradi potreb po preizkusu uporabe metod strojnega učenja kot alternative klasičnim metodam usmerjanja in razvrščanja v porazdeljenih sistemih. Hkrati smo pričakovali uporabnost nekaterih znanstvenih in praktičnih dognanj tako v komercialnih produktih kot tudi v mednarodnih projektih, v katere je podjetje XLAB vpeto.	
	Ocena	Projekt je bil v osnovi postavljen kot logično nadaljevanje razvoja v podjetju XLAB, s poudarkom na raziskavi uporabnosti pristopa z metodami strojnega učenja. Praktični del projekta je bila ocena simulacijskih orodij ter izdelava generičnega vtičnika, kjer je v okviru projekta nastal vtičnik z minimalnim naborom atributov, kar zagotavlja njegovo generičnost. Prav tako je bistvenega pomena, da smo pridobili znanja o zanesljivosti in težavah simulacijskih orodij, ki so rezultat daljše uporabe le-teh in razvoja. Pomembne so tudi pridobljene objave, s katerimi podjetje XLAB lažje konkurira na mednarodnih razpisih.	
2.	Sofinancer		
	Vrednost sofinanciranja za celotno obdobje trajanja projekta je znašala:		EUR
	Odstotek od utemeljenih stroškov projekta:		%
	Najpomembnejši rezultati raziskovanja za sofinancerja		Šifra
	1.		
	2.		
	3.		
	4.		
	5.		
	Komentar		
	Ocena		
3.	Sofinancer		
	Vrednost sofinanciranja za celotno obdobje trajanja projekta je znašala:		EUR
	Odstotek od utemeljenih stroškov projekta:		%
	Najpomembnejši rezultati raziskovanja za sofinancerja		Šifra
	1.		
	2.		

Zaključno poročilo o rezultatih raziskovalnega projekta

		3.		
		4.		
		5.		
	Komentar			
	Ocena			

C. IZJAVE

Podpisani izjavljam/o, da:

- so vsi podatki, ki jih navajamo v poročilu, resnični in točni
- se strinjamo z obdelavo podatkov v skladu z zakonodajo o varstvu osebnih podatkov za potrebe ocenjevanja, za objavo 6., 7. in 8. točke na spletni strani <http://sicris.izum.si/> ter obdelavo teh podatkov za evidence ARRS
- so vsi podatki v obrazcu v elektronski obliki identični podatkom v obrazcu v pisni obliki

Podpisi:

Daniel Vladušič	in/ali	
podpis vodje raziskovalnega projekta		zastopnik oz. pooblaščen oseba RO

Kraj in datum:

Ljubljana

17.4.2009

Oznaka poročila: ARRS_ZV_RPROJ_ZP_2008/170

¹ Samo za aplikativne projekte. [Nazaj](#)

² Napišite kratko vsebinsko poročilo, kjer boste predstavili raziskovalno hipotezo in opis raziskovanja. Navedite ključne ugotovitve, znanstvena spoznanja ter rezultate in učinke raziskovalnega projekta. Največ 18.000 znakov vključno s presledki (približno tri strani, velikosti pisave 11). [Nazaj](#)

³ Realizacija raziskovalne hipoteze. Največ 3.000 znakov vključno s presledki (približno pol strani, velikosti pisave 11). [Nazaj](#)

⁴ Samo v primeru bistvenih odstopanj in sprememb od predvidenega programa raziskovalnega projekta, kot je bil zapisan v predlogu raziskovalnega projekta. Največ 3.000 znakov vključno s presledki (približno pol strani, velikosti pisave 11). [Nazaj](#)

⁵ Navedite največ pet najpomembnejših znanstvenih rezultatov projektne skupine, ki so nastali v času trajanja projekta v okviru raziskovalnega projekta, ki je predmet poročanja. Za vsak rezultat navedite naslov v slovenskem in angleškem jeziku (največ 150 znakov vključno s presledki), rezultat opišite (največ 600 znakov vključno s presledki) v slovenskem in angleškem jeziku, navedite, kje je objavljen (največ 500 znakov vključno s presledki), izberite ustrezno šifro tipa objave po Tipologiji dokumentov/del za vodenje bibliografij v sistemu COBISS ter napišite ustrezno COBISS.SI-ID številko bibliografske enote.

Navedeni rezultati bodo objavljeni na spletni strani <http://sicris.izum.si/>.

PRIMER (v slovenskem jeziku):

Naslov: Regulacija delovanja beta-2 integrinskih receptorjev s katepsinom X;

Opis: Cisteinske proteaze imajo pomembno vlogo pri nastanku in napredovanju raka. Zadnje študije kažejo njihovo povezanost s procesi celičnega signaliziranja in imunskega odziva. V tem znanstvenem članku smo prvi dokazali... (največ 600 znakov vključno s presledki)

Objavljeno v: OBERMAJER, N., PREMŽL, A., ZAVAŠNIK-BERGANT, T., TURK, B., KOS, J.. Carboxypeptidase cathepsin X mediates $\beta 2$ - integrin dependent adhesion of differentiated U-937 cells. Exp. Cell Res., 2006, 312, 2515-2527, JCR IF (2005): 4.148

Tipologija: 1.01 - Izvirni znanstveni članek

COBISS.SI-ID: 1920113 [Nazaj](#)

Zaključno poročilo o rezultatih raziskovalnega projekta

⁶ Navedite največ pet najpomembnejših družbeno-ekonomsko relevantnih rezultatov projektne skupine, ki so nastali v času trajanja projekta v okviru raziskovalnega projekta, ki je predmet poročanja. Za vsak rezultat navedite naslov (največ 150 znakov vključno s presledki), rezultat opišite (največ 600 znakov vključno s presledki), izberite ustrezen rezultat, ki je v Šifrantu raziskovalnih rezultatov in učinkov (Glej: <http://www.arrs.gov.si/sl/gradivo/sifranti/sif-razisk-rezult.asp>), navedite, kje je rezultat objavljen (največ 500 znakov vključno s presledki), izberite ustrezno šifro tipa objave po Tipologiji dokumentov/del za vodenje bibliografij v sistemu COBISS ter napišite ustrezno COBISS.SI-ID številko bibliografske enote.

Navedeni rezultati bodo objavljeni na spletni strani <http://sicris.izum.si/>. [Najaj](#)

⁷ Pomen raziskovalnih rezultatov za razvoj znanosti in za razvoj Slovenije bo objavljen na spletni strani: <http://sicris.izum.si/> za posamezen projekt, ki je predmet poročanja. [Najaj](#)

⁸ Največ 4.000 znakov vključno s presledki [Najaj](#)

⁹ Največ 4.000 znakov vključno s presledki [Najaj](#)

¹⁰ Rubrike izpolnite/prepišite skladno z obrazcem "Izjava sofinancerja" (<http://www.arrs.gov.si/sl/progproj/rproj/gradivo/>), ki ga mora izpolniti sofinancer. Podpisan obrazec "Izjava sofinancerja" pridobi in hrani nosilna raziskovalna organizacija – izvajalka projekta. [Najaj](#)

Obrazec: ARRS-ZV-RPROJ-ZP/2008 v1.00