

UDK 681.3.06/07:316.344
Izvorni znanstveni rad

Digitalna nejednakost

Branimir Krištofić

Institut za društvena istraživanja u Zagrebu, Zagreb, Hrvatska
e-mail: kristof@idi.hr

SAŽETAK U tekstu se analizira proširenost informacijsko-komunikacijske tehnologije, na globalnoj razini prema podacima International Telecommunication Uniona, a u Hrvatskoj prema podacima terenskog empirijskog istraživanja koje je 2004. godine proveo Institut za društvena istraživanja u Zagrebu, na reprezentativnom uzorku punoljetnog stanovništva RH. S obzirom na raširenost telefona, mobitela i interneta, Hrvatska je u evropskom prosjeku, a zaostaje brojem osobnih računala na sto stanovnika. U Hrvatskoj su najjači prediktori digitalne nejednakosti obrazovanje i prihod kućanstva, odnosno, osobna primanja ispitanika. Korisnici interneta bolje su obrazovani i imaju viša primanja od onih ispitanika koji nikada ne koriste internet. Statistički značajne razlike utvrđene su i s obzirom na dob i mjesto stanovanja dok su male razlike kad je riječ o spolu. Korisnici interneta mladi su ljudi, pretežno žive u gradovima, a među njima je nešto više muškaraca, nego žena. Utvrđena je i razlika s obzirom na broj članova kućanstva. Internet se najviše koristi u obiteljima koje imaju četiri ili tri člana. Pokazano je da se digitalna nejednakost veže uz već postojeće društvene nejednakosti. Stoga se digitalni jaz, kao bitni oblik nejednakosti informacijskog doba (Castells), ne može preskočiti, nego se smanjuje u mjeri u kojoj se smanjuju društvene nejednakosti.

Ključne riječi: digitalna podijeljenost, digitalna nejednakost, društvene nejednakosti, internet, informacijsko doba, Manuel Castells.

Primljeno: listopad 2007.

Pribvačeno: listopad 2007.

1. Uvod

“Da znam s internetom, ne bih bila tu! Što oni znaju imam li koga mladega da zna s kompjutorima, žestila se starija gospođa čekajući da se nakon dva sata na zaslonu pokaže njezin broj.” Citirana rečenica je iz reportaže o zagrebačkoj gruntovnici u kojoj je i nakon digitalizacije zemljišnih knjiga gužva velika i redovi dugi, pa ljudi “gube živce” i glasno protestiraju. Oni koji znaju s internetom drže da je digitalizacija zemljišnih knjiga “poboljšala stanje” i omogućila da svatko “može vidjeti u kojoj je fazi predmet, a bilo bi još bolje kad bi referenti odgovarali na e-mailove”. Na

Copyright © 2007 Institut za društvena istraživanja u Zagrebu – Institute for Social Research in Zagreb
Sva prava pridržana – All rights reserved

stranici do spomenute reportaže objavljena je mala vijest da Grad Rijeka organizira besplatni informatički tečaj za odrasle, točnije “za umirovljenike i kućanice starije od 50 godina, te za umirovljene hrvatske branitelje i građane s posebnim potrebama” (Novi list, 2. 4. 2007.:12/13). Grupe za koje se tečaj organizira očito se smatra “digitalno ugroženima” pa im treba pomoć u snalaženju s novim tehnologijama.

Miroslav Kovačić, državni tajnik Središnjeg državnog ureda za e-Hrvatsku, najavljuje nova “čuda” koja očekuju građane. Do kraja 2009. godine osobna iskaznica moći će se dobiti putem interneta. Poslije 2010. pregleda kod liječnika specijaliste zakazivat ćemo putem interneta, liste čekanja bit će transparentne, recepti za lijekove bit će u elektronskom obliku. Informatizacijom zdravstva kontrolirat će se troškovi pa će se napokon “moći jasno vidjeti na što se troši toliki novac u zdravstvu”. Kad je riječ o sudstvu predmeti će se “kompjutorski dodjeljivati sucima pa više neće biti namještanja sudskih postupaka”. I hrvatski premijer smatra da je projekt e-Hrvatska, pored boljitaka koje donosi građanima, i “način borbe protiv birokracije, a time i korupcije” (Sanader, 2007.:29). Informatizacijom državne uprave nitko od zaposlenih u upravi neće izgubiti posao, nego će biti raspoređeni na nova radna mjesta. S građanima će se više komunicirati telefonom, internetom i putem e-maila pa će se tako, smatra Kovačić, “riješiti i veliki psihološki problemi svih tijela državne uprave koji su, kako kaže, ljudima nerijetko odbojni, najčešće zbog neljubavnosti službenika”. Što se tiče informatizacije, najviše je učinjeno u školstvu. Studenti “imaju svoju karticu kojom prijavljuju ispite, idu u menzu, peru odjeću ...”. Svaka škola “ima osposobljenu informatičku radionicu, svako dijete može imati svoj e-mail, a škole mogu izrađivati i svoju web-stranicu”. No, unatoč svemu tomu istraživanja pokazuju da više od polovice učenika u Zagrebu i velikim gradovima u školi nikada ne koristi računalo (Batarelo; Marušić, 2006.:207). Kovačić smatra da “nije toliko teško osposobiti uslugu koliko natjerati ljude da se njome koriste. (...) Ljudi naime imaju nepotreban strah od kompjutora, misle da će nešto pokvariti ako stisnu krivu tipku, što naravno nije točno. Taj strah treba prevladati informacijom i edukacijom” (Nacional.hr, 26. 7. 2007.). Pero Lučin, prorektor Sveučilišta u Rijeci i član skupine za vođenje pregovora s EU-om, razmišlja o budućnosti školstva i najavljuje generaciju koja se sigurno ne boji računala. Stiže “generacija ‘Y’ kojoj je jedna od najbitnijih karakteristika upravljanje protokom informacija. Mladi ljudi koji sjede za računalom i u isto vrijeme mogu obavljati nekoliko poslova, komunicirati, slušati glazbu, učiti matematiku, nemaju nikakav poremećaj, kao što se može čuti. (...) Generaciju ‘Y’ ne zanima kako funkcionira tehnologija, oni žele što brži pristup mreži”. Prema Lučinu, za tu generaciju “škole se moraju pripremiti za školska razdoblja od četiri sata, a ne od 45 minuta, interdisciplinarnu pristupe, rad u grupama od 90 do 120 učenika...” (Novi list, 2. 4. 2007.:12/13).

Imate li pristup internetu, citirane članke možete pročitati i na ekranu svog računala. Gospođa iz zagrebačke grunтовnice i vi nalazite se na različitim stranama digitalnog jaza. Upravo mogućnost pristupa internetu određuje digitalnu nejednakost, digitalnu podijeljenost ili digitalni jaz. Ljudi se dijele na one koji taj pristup imaju i one koji ga nemaju. No, problem prevladavanja jaza nije samo u savladavanju

straha. “Razlikovanje onih koji imaju i onih koji nemaju pristup internetu dodaje još jednu temeljnu podjelu već postojećim izvorima nejednakosti i društvene isključenosti u složenoj interakciji koja, čini se, povećava prazninu između obećanja informacijskog doba i njegove sive realnosti za većinu ljudi širom svijeta” (Castells, 2003.a:271). S 21. stoljećem, po Castellsu, zakoračili smo u novo informacijsko doba i novo umreženo društvo (Castells, 2000.a; 2000.b; 2003.b). Genezu tog novog društva Castells vidi u procesima koji su se odvijali šezdesetih i sedamdesetih godina prošlog stoljeća: informacijskoj revoluciji, ekonomskoj krizi kapitalizma i socijalizma, kao i bujanju novih društvenih pokreta. No, najvažnije mjesto ipak pripada informacijskoj revoluciji koja je, po Castellsu, omogućila restrukturiranje kapitalizma i dovela do propasti socijalizma. Sovjetski Savez propustio je revoluciju informacijskih tehnologija što se na koncu pokazalo “glavnim čimbenikom njegova pada” (Castells, 2003.b:47). Zanimljivo je da rušenje Berlinskog zida kao simbolički početak kraja socijalizma i uspostavljanje World Wide Weba kao simboličkog početka brzog širenja interneta padaju u istu 1989. godinu” (Norris, 2000.: Chapter 1, 1). Ta dva događaja svakako su pogodovala da informacijska tehnologija postane “neophodno sredstvo za učinkovitu provedbu procesa društveno-ekonomskog restrukturiranja. Imala je osobito važnu ulogu u razvoju umrežavanja kojemu je omogućila da postane dinamičan samošireći oblik organizacije ljudskih aktivnosti. Ta vladajuća logika umrežavanja preobrazila je sva područja društvenog i ekonomskog života” (Castells, 2003.b:360–361). Zadatak je sociologa da analiziraju i ljudima objašnjavaju nove društvene procese kako ne bi došlo do blokade promjena i izgubio se “izvanredan potencijal sadržan u vrijednostima i tehnologiji informacijskog doba” (Castells, 2000.b:693). Iz te perspektive digitalna nejednakost jedan je od ključnih problema suvremenog društva. Kritičari koji nisu suglasni s tezom da živimo u posve novom informacijskom dobu (Webster, 2002.) ili smatraju da je najslabija točka Castellsove konceptualizacije informacijskog društva kauzalna logika koja iz “vladajuće logike umrežavanja” izvodi sve društvene promjene (van Dijk, 1999.) ne negiraju promjene, nego ih drukčije tumače. Zadatak ovog teksta nije raspravljati o konceptu informacijskog doba ili umreženog društva, nego na podacima prikupljenim empirijskim istraživanjima vidjeti kako Hrvatska s obzirom na promjene o kojima je riječ stoji u usporedbi s drugim zemljama, te koliko su te promjene prisutne u Hrvatskoj. Nadalje, intencija je vidjeti i koje su razlike među društvenim grupama s obzirom na dostupnost i prihvaćanje informacijsko-komunikacijske tehnologije.

2. Globalna digitalna nejednakost

Kada se pogleda karta svijeta na kojoj su zemlje obojene tonovima od crne do bijele boje prema postotku “on-line” populacije, crne se Australija i Novi Zeland, Sjeverna Amerika i sjever Evrope. Sve ostalo su tonovi sive s velikim bjelinama naročito u Africi i Aziji (Castells, 2003.:232). Osim broja korisnika interneta (na koje se odnosi spomenuta karta) u tablici 1. prikazani su i podaci Internacionalne telekomunikacijske unije (ITU) o broju (na 100 stanovnika) pretplatnika klasičnih telefonskih linija i mobitela, te broju instaliranih osobnih računala.

Iz podataka je jasno vidljivo koliko su “obećanja informacijskog doba” za dobar dio svjetske populacije još uvijek nedostupna. Prva komercijalna telefonska linija putem koje su pretplatnici mogli čuti jedan drugoga na udaljenost do dvadeset milja uspostavljena je u New Havenu 28. siječnja 1878. godine (Hannemyr, 2003.:113). Tako je prije gotovo 130 godina telefon postao prvo komercijalno tehnološko sredstvo komunikacije na daljinu. Podaci pokazuju kako pretplatnici klasičnih telefonskih linija 2005. godine jedva da prelaze polovicu svjetske populacije, a klasični telefon još je uvijek osnovna infrastruktura širenja interneta i time prodiranja umreženog društva. U Africi samo pet zemalja ima više od 50 pretplatnika na 100 stanovnika (Sejšeli, Južna Afrika, Mauricijus, Tunis i Bocvana). Najveći GDP *per capita* u Africi ima Ekvatorijalna Gvineja, no tek dvadeset i jednog telefonskog pretplatnika na 100 stanovnika. Libija ima gotovo dva puta veći GDP od Tunisa i četiri puta manje telefonskih pretplatnika, te preko pet puta manje pretplatnika od Južne Afrike od koje ima tek neznatno manji GDP *per capita* u američkim dolarima.

Tablica 1.
Informacijsko-komunikacijska tehnologija u svijetu

Na 100 stanovnika	Telefonskih pretplatnika		Mobitel – pretplatnika		Instaliranih PC-a		Korisnika interneta		
AFRIKA	18.48	97.21	15.34	71.60	2.20	36.31	3.74	27.99	max
		1.32		0.53		0.07		0.19	min
AMERIKE	86.14	173.08	53.04	135.11	35.33	76.22	34.23	67.89	max
		6.58		1.20		1.57		1.69	min
AZIJA	38.45	177.41	22.98	123.74	6.36	73.40	9.64	68.35	max
		1.27		0.34		0.28		0.06	min
EVROPA	125.12	207.41	83.55	154.83	30.69	86.18	32.02	87.76	max
		48.02		37.04		3.89		6.01	min
OCEANIJA	106.55	141.60	68.78	91.39	50.46	68.90	53.21	70.40	max
		2.36		0.72		1.89		0.84	min
SVIJET	53.42	207.41	34.05	154.83	13.36	86.18	15.23	87.76	max
		1.27		0.34		0.07		0.06	min
HRVATSKA	121.53		80.18		19.07		32.35		

Izvor: International Telecommunication Union, 2005.

Na dnu su Etiopija i Eritreja sa 146 odnosno 134 US-dolara po stanovniku i 1,32 odnosno 1,78 telefonskih pretplatnika na 100 stanovnika. Slično je i s pretplatnicima mobilnih telefona. Samo francuski departman Réunion, Južna Afrika, Sejšeli, Tunis i Mauricijus imaju ih više od 50 posto. Računala i internet za veliku su većinu stanovnika afričkih zemalja gotovo nepoznanica. Bolje je stanje u navedenim zemljama koje imaju razvijenu telefonsku infrastrukturu, no nema nijedne zemlje u kojoj je korisnika interneta više od 30 na 100 stanovnika.

Obje Amerike telefonskom su mrežom mnogo bolje pokrivena iako jako zaostaju Kuba s 8,80 posto i Haiti sa 6,58 posto telefonskih pretplatnika. Ispred najrazvi-

jenijih zemalja, SAD-a i Kanade, male su otočne državice u Karibima (Aruba i Antigva i Barbuda) sa 173 odnosno 150 pretplatnika na 100 stanovnika. Najviše pretplatnika mobitela na 100 stanovnika imaju Jamajka (105,78) i Antigva i Barbuda (105,55), Barbados (76,65), Bermuda (76,63), francuski prekomorski teritoriji Martinique (74,78) i Guadeloupe (71,04), a tek potom SAD (71,43). Ispred Kanade (52,51), po broju pretplatnika mobitela na 100 stanovnika, niz je zemalja Srednje i Južne Amerike, a na začelju su Peru (19,96), Haiti (4,87) i Kuba (1,20).

No, Kanada i SAD daleko odskaču po broju instaliranih osobnih računala i korisnika interneta. Informacijsko doba najgore stoji na Kubi koja ima manje od četiri računala i manje od dva korisnika interneta na 100 stanovnika.

S obzirom na broj telefonskih pretplatnika Aziju predvode Hong Kong, Tajvan i Izrael, a mobilnih telefona najviše je, također, u Hong Kongu, te u Makau i Izraelu. Na dnu liste je Mijanmar sa svega 1,27 telefonskih i 0,34 pretplatnika mobitela na 100 stanovnika. Osobnih računala relativno je najviše u Izraelu (73,40 na 100 stanovnika), a najmanje u Afganistanu (0,28). Najviše populacije on-line je u Južnoj Koreji (68,35%) dok u Mijanmaru na 100 stanovnika dolazi samo 0,06 korisnika interneta. Japan, s najvećim GDP-om *per capita* u Aziji u svim kategorijama stoji vrlo visoko, no nijednu ne predvodi. Oceanijom u svim kategorijama dominiraju Australija i Novi Zeland, a začelje drži Papua Nova Gvineja.

Već je iz tablice 1. vidljivo da su u Evropi u usporedbi s drugim kontinentima razlike među zemljama najmanje i to naročito u telefoniji. Manje od 50 pretplatnika telefona na 100 stanovnika samo je u Albaniji (48,05) i Moldovi (48,02). Najviše ih je u Luksemburgu koji je i svjetski rekorder s 207,41 pretplatnika na 100 stanovnika. Hrvatska je, kao što se vidi iz tablice 1., vrlo blizu prosjeka Evrope. Mobiteli su, također, premrežili Evropu. I tu vodi Luksemburg (154,83), a slijedi ga Litva (127,10). Manje od 50 pretplatnika mobitela na 100 stanovnika je u Albaniji (39,45), Bjelorusiji (42,01), Bosni i Hercegovini (40,81), Moldovi (25,92), Monaku (48,76) i Ukrajini (37,04). Hrvatska sa svojih 80 pretplatnika na 100 stanovnika opet je vrlo blizu prosjeka Evrope i izjednačena je s Francuskom. Mnogo veće razlike u Evropi pojavljuju se s obzirom na broj računala i korisnika interneta. Najviše osobnih računala na 100 stanovnika je u Švicarskoj (86,18), a slijede je Švedska (76,14), Nizozemska (68,47), Danska (65,48) i Luksemburg (62,37). Začelje drže Ukrajina (3,89), Srbija i Crna Gora (4,77 – podaci se odnose na 2005. godinu dok Crna Gora još nije proglasila samostalnost), Turska (5,13) i nova članica EU-a Bugarska (5,94). Hrvatska s 19,07 računala na 100 stanovnika zaostaje za prosjekom, no još uvijek je ispred, primjerice, Grčke (8,88), Portugala (13,32) ili Malte (16,61) koje od Hrvatske imaju daleko veći GDP *per capita*. Kada je riječ o korisnicima interneta, zanimljivo je da Švicarska, koja ima relativno najviše računala ima "samo" 50,93 korisnika interneta na 100 stanovnika i daleko je iza Islanda (87,76), Švedske (76,21) i Nizozemske (73,99). Najmanje je korisnika interneta u Albaniji (6,01), Makedoniji (7,86) i Ukrajini (9,81). Hrvatska (32,35) je točno u prosjeku Evrope, opet bolja od Portugala (28,01) i Grčke (17,99), a izjednačena s Maltom (31,73).

Već i ovako letimičan pregled širenja informacijsko-komunikacijskih tehnologija pokazuje da je informacijsko doba prije svega stvar razvijenih zemalja, iako veza između razvijenosti i proširenosti tehnologije nikako nije linearna. Švedska, primjerice, ima samo nešto veći GDP *per capita* od Francuske, a daleko je nadmašuje i relativnim brojem računala i korisnika interneta. Estonija ima gotovo jednako korisnika interneta (51,92) kao i Danska (52,55) i šest i pol puta manji GDP *per capita*. Kao važne za širenje informacijsko-komunikacijske tehnologije, istraživanja navode i cijenu pristupa internetu, razvijenost infrastrukture, konkurenciju telekomunikacijskih servisa, te prosječan životni standard i prosječan stupanj obrazovanja u nekoj zemlji (Guillén; Suárez, 2005.:683–684). Politički faktori ponekad igraju odlučujuću ulogu. Na Kubi je pristup internetu moguć samo za odabrane na sveučilištu i za neka radna mjesta, a individualnog pristupa internetu nema. Slično je i u Mijanmaru gdje svaki vlasnik računala mora imati licencu i nema javnog pristupa internetu (Guillén; Suárez, 2005.:688). Podaci koje smo naveli pokazuju da Kuba i Mijanmar na svojim kontinentima zauzimaju posljednja mjesta u proširenosti informacijsko-komunikacijske tehnologije.

Za Castellsa, informacionalizam je jedini mogući put razvoja, put u informacijsko doba. Ako se i uzme u razmatranje “alternativne modele razvoja, manje oslonjene na tehnologiju, možda s manjom proizvodnjom i sporijim materijalnim napretkom, no bliže povijesti, kulturi i prirodnim uvjetima pojedine države, što bi vjerojatno više zadovoljavalo većinu njezinih stanovnika (...) prekasno je da bismo mogli dopustiti tu vrstu opuštenih razmatranja. Ekonomija i informacijski sustav koji se temelje na internetu (i razvijaju se brzinom interneta) ograničili su puteve razvoja na malen broj mogućnosti” (Castells, 2003.a:293–294). Izboru, zapravo, nema. Možemo se umrežiti ili propasti. Izneseni podaci pokazuju da su razlike na globalnoj razini tolike da je upitno može li se “vladajuća logika umrežavanja” nametnuti većini zemalja. Ako gotovo pola svjetske populacije nema pristup telefonu, tada bi iz predindustrijskog trebali izravno ući u postindustrijsko, informacijsko doba. “Novi model razvoja zahtijeva preskakanje planetarne digitalne podjele” (Castells, 2003.a:295). No, takvi su skokovi rijetko, ako i ikako mogući.

3. Digitalna nejednakost u Hrvatskoj

Podaci koje ćemo prikazati prikupljeni su terenskim istraživanjem koje je proveo Institut za društvena istraživanja u proljeće 2004. godine. Upitnik je sadržavao niz pitanja iz različitih područja sociologije i nije posebno dizajniran za istraživanje širenja interneta. No, postavljena su pitanja o opremljenosti kućanstva računalima, priključkom na internet, te koriste li ispitanici internet u slobodno vrijeme. Strana istraživanja korisnika interneta razlikuju nekoliko dimenzija pristupa. Tako Jan van Dijk govori o “materijalnom pristupu” (posjedovanje računala i priključka na internet), “mentalnom pristupu” (nedostatak iskustva, strah od računala, nezainteresiranost za nove tehnologije), “nedostatku digitalnih vještina” (neodgovarajuće obrazovanje i izostanak društvene potpore), te o “manjku mogućnosti uporabe”. Također se istražuje za što se računala i internet

koriste – mijenja li internet “potrošnju” vremena, mijenja li odnose u obitelji, socijalnost korisnika interneta pa sve do uloge interneta u politici i javnom životu (van Dijk; Hacker, 2003.; vidi i DiMaggio et al., 2001.). Sličnih istraživanja kod nas gotovo da nema. Provedeno je istraživanje o korištenju interneta u školama (Batarello; Marušić, 2006.:207). Istraživanjem širenja interneta još uvijek se najviše bave agencije za istraživanje tržišta (vidi npr. <http://www.gfk.hr>) gdje se na korisnike interneta prije svega gleda kao na moguće potrošače i publiku za oglašivače.

S obzirom na podatke kojima raspolažemo, možemo analizirati samo opremljenost kućanstva informacijsko-komunikacijskom tehnologijom te obilježja korisnika interneta. Ne možemo odgovoriti na pitanja o sadržaju upotrebe interneta.

Uzorkom je obuhvaćeno 2.220 ispitanika (opis uzorka vidi u Hodžić, 2005.:520/521). Riječ je o proporcionalnom stratificiranom slučajnom uzorku punoljetnog stanovništva Hrvatske. U uzorak nisu uključeni studenti i učenici. U toj je grupi sigurno mnogo korisnika interneta, no u ukupnoj populaciji punoljetnih učenika i studenata nema više od dva do tri posto. Prednost je ovog uzorka, za razliku od uzoraka učenika ili studenata, što uključuje sve one obitelji koje nemaju djecu u školi (samačka ili starija dvočlana domaćinstva, obitelji s odraslom djecom, obitelji koje ne žive s djecom...) pa osigurava bolju reprezentativnost ukupne populacije.

3.1. Opremljenost kućanstava informacijsko-komunikacijskom tehnologijom

Kada se usporede statistički podaci ITU-a u tablici 1. i podaci istraživanja u tablici 2. uočljive su neke razlike, no u tablici 2. riječ je o postotku kućanstava, a u tablici 1. o postotku stanovništva. Podatke o opremljenosti kućanstva informacijsko-komunikacijskim tehnologijama ukrstili smo s tipom naselja u kojoj obitelj živi, brojem članova i prihodom po članu obitelji.

3.1.1. Opremljenost kućanstava informacijsko-komunikacijskom tehnologijom prema tipu naselja

Prema podacima istraživanja na selu živi četvrtina ispitanika, a nešto više od četvrtine u Zagrebu (17,2%) ili velikim makroregionalnim centrima (Split, Rijeka, Osijek – 10,8%). Ostali su raspoređeni između seoskih (19,4%), širih (9,1%) i regionalnih (18,5%) lokalnih centara.

Tablica 2.

Opremljenost kućanstava informacijsko-komunikacijskom tehnologijom prema tipu naselja stanovanja

Tip naselja/postotci	Telefon	Mobitel	PC	Internet
Selo	87.7	72.1	23.8	18.9
Seoski lokalni centar	87.5	79.1	27.6	21.6
Širi lokalni centar	88.7	86.7	45.3	40.9
Regionalni centar	90.7	81.7	42.0	37.6
Makroregionalni centar	88.3	83.3	50.4	40.4
Zagreb	92.1	82.4	52.2	41.2
Hrvatska – prosjek	89.1	79.5	37.6	31.0
Pearsonov Hi-kvadrat	7.144	30.711	123.500	101.728
df =	5	5	5	5
p <	0.210	0.000	0.000	0.000
Koeficijent kontingencije	0.057	0.117	0.230	0.209

S obzirom na tip naselja u posjedovanju telefonskog priključka nema statistički značajnih razlika između sela i gradova. Razlike u posjedovanju mobitela statistički su značajne, ali nisu velike. Mnogo su veće razlike u posjedovanju osobnog računala (PC-a) i priključka na internet. Računalo posjeduje više od polovice kućanstava u Zagrebu i samo oko četvrtine u selima i njima bliskim lokalnim centrima. Na internet je priključeno oko dvije petine kućanstava u gradovima i oko jedne petine u selima i seoskim lokalnim centrima. S obzirom na posjedovanje računala Batarelo i Marušić dobile su slične relativne odnose, no mnogo više postotke za sve tipove naselja (Batarelo; Marušić, 2006.:206). Kako je njihov uzorak obuhvatio učenike osmih razreda osnovnih škola koji u velikom postotku dolaze iz obitelji s tri ili četiri člana, vjerojatno je ta varijabla “povećala” broj računala.

3.1.2. Opremljenost kućanstava informacijsko-komunikacijskom tehnologijom prema broju članova obitelji

U realiziranom uzorku gotovo trećina (31,8%) su samačka ili dvočlana domaćinstva, tročlanih je 19,5 posto, četveročlanih je 25,5 posto, a obitelji s pet ili više članova 23,1 posto.

Tablica 3.

Opremljenost kućanstva informacijsko-komunikacijskom tehnologijom prema broju članova obitelji

Broj članova/postotci	Telefon	Mobitel	PC	Internet
Jedan	74.7	34.6	13.2	9.7
Dva	87.3	58.7	21.1	18.0
Tri	90.5	90.1	40.6	33.7
Četiri	91.7	94.4	54.0	46.9
Pet i više	94.0	95.1	43.7	33.3
Hrvatska – prosjek	89.1	79.5	37.6	31.0
Pearsonov Hi-kvadrat	73.869	621.76	191.678	157.750
df =	4	4	4	4
p <	0.000	0.000	0.000	0.000
Koeficijent kontingencije	0.179	0.468	0.282	0.259

Podaci u tablici 3. pokazuju da broj članova kućanstva generira veće razlike od mjesta stanovanja. Kućanstva s jednim ili dva člana daleko zaostaju za onima koja imaju tri ili više članova. Statistički su značajne i razlike u posjedovanju telefona i mobitela. Četvrtina samačkih kućanstava ne posjeduje telefon, a gotovo dvije trećine nema mobitel. Četiri puta je manje samačkih kućanstava koja posjeduju računalo, nego obitelji s četiri člana. S obzirom na internet-priključak, taj odnos je jedan prema pet. No, kod samaca kumuliran je niz osobina koje ne pogoduju prihvaćanju informacijsko-komunikacijskih tehnologija. Riječ je o ljudima prosječno starim 62 godine, od toga su 64 posto žene, 71 posto umirovljenici i 54 posto s osnovnim obrazovanjem.

Velike razlike dobivene su i ukrštanjem s varijablom prihoda po članu kućanstva. Prihod kućanstva značajno proizvodi "digitalni jaz" i u razvijenim zemljama Evrope i u SAD-u (van Dijk; Hacker, 2003.; DiMaggio et al., 2001.).

3.1.3. Opremljenost kućanstava informacijsko-komunikacijskom tehnologijom prema prihodu po članu obitelji

Kada je riječ o prihodu obitelji i osobnim primanjima ispitanika treba napomenuti da ih ne valja uspoređivati s prosječnim plaćama, jer uzorak uključuje nezaposlene, umirovljenike i domaćice čija su primanja značajno niža (a neki ispitanici uopće nemaju osobnih primanja) od prosječnih plaća, pa su i ukupni prosjeci niži. Do 1.000 kuna prihoda po članu kućanstva ima 29,4 posto obitelji, 40,3 posto od 1.000 do 2.000 kuna, 20 posto od 2.000 do 3.000 kuna, 6,4 posto od 3.000 do 4.000 kuna i više od 4.000 kuna 4,1 posto obitelji.

Tablica 4.

Opremljenost kućanstva informacijsko-komunikacijskom tehnologijom prema prihodu po članu obitelji

Prihod po članu/postotci	Telefon	Mobitel	PC	Internet
Do 1.000 kn	83.4	70.7	22.9	14.1
Od 1.001 do 2.000 kn	90.6	78.1	34.6	28.4
Od 2.001 do 3.000 kn	92.6	88.3	50.8	45.8
Od 3.001 do 4.000 kn	94.3	92.1	61.0	57.4
Preko 4.000 kn	91.1	95.6	73.3	65.6
Hrvatska – prosjek	89.1	79.5	37.6	31.0
Pearsonov Hi-kvadrat	33.509	81.125	178.640	231.461
df =	4	4	4	4
p <	0.000	0.000	0.000	0.000
Koeficijent kontingencije	0.122	0.188	0.273	0.307

Kućanstva s najvišim prihodom po posjedovanju osobnog računala i priključka na internet u prosjeku su najrazvijenijih evropskih zemalja, dok su ona s najmanjim prihodom u prosjeku ili ispod prosjeka najnerazvijenijih. Tako u Hrvatskoj možemo naći cijeli raspon evropske digitalne nejednakosti. Kako bi se preskočilo ne samo planetarnu nego i lokalnu digitalnu podjelu, prije svega je očito potreban viši dohodak. Prema tome strah se od računala najbolje prevladava povišenjem standarda.

3.2. Korisnici interneta

Kao korisnici interneta određeni su oni ispitanici koji su pozitivno odgovorili na pitanje koriste li internet u slobodno vrijeme. Onih koji su odgovorili da nikada ne koriste internet je 72,5 posto. Internet rijetko koristi 6 posto, mjesečno 2,1 posto, tjedno 7,8 posto i dnevno 11,6 posto ispitanika. Zbog pojednostavljenja obrade podataka sve smo kategorije korisnika saželi u jednu pa imamo 72,5 posto ispitanika koji nikada ne koriste internet i 27,5 posto onih koji ga koriste.

Kao i kod varijabli o opremljenosti kućanstva najmanje je korisnika interneta na selu (11,9%), a najviše u Zagrebu (42,8%). Najmanje je korisnika interneta kod samačkih domaćinstava (12,1%), a najviše među onima koji žive u četveročlanim obiteljima (39,3%). Broj ispitanika on-line raste kako raste prihod po članu kućanstva. U kućanstvima s najnižim prihodom svega je 12,4 posto ispitanika koji koriste internet, dok u kućanstvima s najvišim prihodom internet koristi 70 posto ispitanika.

3.2.1. Korisnici interneta prema spolu i dobi

Internetom se koristi 54,1 posto muškaraca i 45,9 posto žena. Iako statistički značajna ($\chi^2 = 13,791$; $df = 1$; $p < 0,000$) razlika je mala (koeficijent kontingencije – dalje $CC = 0,079$). Svjetska istraživanja pokazuju da su razlike po spolu značajne u ranijim fazama širenja interneta, no poslije se gube i spol je jedan od najslabijih prediktora digitalne nejednakosti (Norris, 2000.: chapter 4:9).

Za razliku od spola dob je izuzetno značajan prediktor. Internet je medij mladih ljudi, pa korisnika interneta među ispitanicima u dobi do 30 godina ima 51,6 posto, a među starijima od 60 godina samo 3,1 posto (31 do 40 godina – 40,8%; 41 do 50 godina – 30,6%; 51 do 60 godina – 16,4%; $\chi^2 = 367,843$; $df = 4$; $p < 0,000$; $CC = 0,377$). Ljudi koji danas imaju između 30 i 40 godina bili su gimnazijalci ili studenti kada je početkom devedesetih godina počelo širenje interneta pa možemo reći da su uz internet odrastali. Osim toga, bolje su obrazovani od starijih ispitanika. I evropska istraživanja pokazuju da je dob jak prediktor digitalne nejednakosti koji ne gubi na značaju širenjem interneta (Norris, 2000.: chapter 4:9).

3.2.2. Korisnici interneta prema obrazovanju, zanimanju i osobnim primanjima

Još veće razlike od dobi generira obrazovanje. Među ispitanicima koji su završili osmogodišnju školu ili imaju nepotpuno osnovno obrazovanje samo je 6 posto korisnika interneta. Korisnika interneta među ispitanicima koji su završili škole za radnička zanimanja je 23,5 posto, među onima koji su stekli srednje obrazovanje 44,7 posto, više obrazovanje 51,8 posto i visoko obrazovanje 77,4 posto ($\chi^2 = 510,629$; $df = 4$; $p < 0,000$; $CC = 0,432$). Uz obrazovanje vežu se i razlike po zanimanjima. Najviše je korisnika interneta među zanimanjima za koja je potrebno više ili visoko obrazovanje. Tako je na internetu najviše stručnjaka (76,9%) i rukovodilaca (73,8%). Kod radničkih zanimanja postotci se kreću od 9,7 posto za industrijske radnike do 21,6 posto za radnike u transportu. Internetom se više koriste trgovci (44,5%), radnici u uslugama (35,9%) i službenici (56,6%). Najmanje je korisnika interneta među umirovljenicima (5,4%) i domaćicama (9,1%), dok nezaposleni stoje prilično dobro s 35,1 posto. No nezaposleni su puno mladi (51,7% mlade je od 30 godina) i obrazovaniji (72,3% ima završenu srednju školu) od ukupne populacije pa su time i “predodređeni” da više koriste internet.

Treba spomenuti da je korištenje interneta kod kuće statistički značajno povezano i s korištenjem interneta na poslu. Od ukupnog uzorka posloprimaca njih 25,9 posto internet koristi u oba slučaja ($\chi^2 = 266,994$; $df = 1$; $p < 0,000$; $CC = 0,486$).

Korištenje interneta u korelaciji je i s obrazovanjem roditelja i to više majke ($\chi^2 = 495,838$; $df = 10$; $p \leq 0,000$; $CC = 0,427$) nego oca ($\chi^2 = 428,176$; $df = 10$; $p < 0,000$; $CC = 0,402$). Broj korisnika interneta počinje rasti čim je obrazovanje roditelja više od osnovnog. Među ispitanicima čiji otac ima visoko obrazovanje 75 posto koristi internet, a ako je majka visokoobrazovana čak 80 posto.

Kao i kod prihoda kućanstva učestalost korištenja interneta raste s visinom osobnih mjesečnih primanja. Internet koristi 14,3 posto ispitanika s najnižim prihodima (do 2.000 kuna), 26 posto ispitanika s prihodima između 2.000 i 3.000 kuna, 47,9 posto ispitanika s prihodima između 3.000 i 4.000 tisuće kuna i 59,9 posto onih s najvišim prihodima (više od 4.000 kuna). Tako je među onima s najvišim prihodima četiri puta više korisnika interneta, nego među ispitanicima s najnižim prihodima ($\chi^2 = 333,656$; $df = 3$; $p < 0,000$; $CC = 0,361$).

3.2.3. Osnovni profil korisnika interneta

Tko su ljudi koji “surfaju”internetom? U velikoj većini žive u gradovima. Internetom se nešto češće koriste muškarci, nego žene. Prosječna dob im je 36 godina. Obitelj ima tri ili četiri člana i višeg je imovinskog statusa. “Surfer” ima završenu barem srednju školu, a često i više ili visoko obrazovanje. Radi kao stručnjak ili, rjeđe, kao službenik, odnosno, radnik u uslugama. Velika je vjerojatnost da se internetom služi i na poslu. Ima natprosječna mjesečna primanja.

Tko se nalazi s druge strane digitalnog jaza? Ljudi koji žive na selu i u manjim mjestima. Nešto više žene, nego muškarci. Prosječna dob onih koji nikada ne koriste internet je 52 godine. Iako najstariji anketirani “surfer” ima 76 godina, među ljudima starijim od 60 godina korisnika interneta je zanemarivo malo. Internet nikada ne koristi 87,9 posto samaca i 82 posto onih čija obitelj broji dva člana. Onih koji nikada ne koriste internet najviše je među umirovljenicima, domaćicama, poljoprivrednicima i radnicima. Po obrazovanju najviše je onih koji (ni)su završili osmogodišnju ili su završili škole za radnička zanimanja. Većina ulazi u kategoriju najnižih primanja. Digitalne nejednakosti su očite. Treba pogledati koje ih varijable najviše proizvode.

4. Zaključna razmatranja

U tablicu 5. uvršteni su koeficijenti kontingencije varijabli koje smo već prikazali kako bismo na jednome mjestu mogli analizirati korelaciju između korištenja interneta i promatranih varijabli. Vrijednosti koeficijenta kontingencije mogu biti između nula i jedan, a veza između varijabli je to veća što je vrijednost koeficijenta viša.

Najveće razlike u korištenju interneta generiraju varijable vezane uz zanimanje i obrazovanje. Veza zanimanja i obrazovanja ispitanika izuzetno je visoka ($CC = 0,658$), a visoke su i korelacije između varijable obrazovanje ispitanika i obrazovanja oca ($CC = 0,402$), obrazovanja majke ($CC = 0,503$) i obrazovanja bračnog partnera ($0,457$).

Tablica 5.
Koeficijenti kontingencije promatranih varijabli s varijablom korištenja interneta

Varijabla	CC	Varijabla	CC
Tip naselja	0,262	Obrazovanje ispitanika	0,432
Broj članova kućanstva	0,205	Obrazovanje oca	0,402
Prihod po članu	0,338	Obrazovanje majke	0,427
Spol	0,079	Zanimanje	0,477
Dob	0,377	Osobna primanja	0,361

Navedene veze pokazuju da je obrazovanje kumulativna varijabla, ili kako bi rekao Bourdieu, akumulirani kulturni kapital. Po Bourdieu obrazovanje je institucionalizirani kulturni kapital koji ovisi o “prethodnim investicijama obitelji” (Bourdieu, 1986.:244). Koeficijenti kontingencije ukrštanja obrazovanja oca i majke to jasno potvrđuju. Kako najobrazovaniji najviše koriste internet, očito je da prihvaćanje interneta ne ovisi (samo) o njihovim “prirodnim” sposobnostima, nego i o naslijeđenom i stečenom kulturnom kapitalu. “Digitalni kapital” tu se očito usaduje u zatečene društvene nejednakosti.

Generacijski jaz u prihvaćanju interneta koji su mnogi spremni tumačiti otvorenošću mladih prema novim tehnologijama također je povezan s obrazovanjem, odnosno, kulturnim kapitalom u Bourdieuovom određenju. Mladi su, naime, oni koji nasljeđuju kulturni kapital. Među našim ispitanicima mladim od 30 godina 14,9 posto je onih s osnovnim obrazovanjem, dok je među starijima od 60 godina takvih 65,3 posto. Najmlađa skupina ima 67,8 posto srednje obrazovanih, a najstarija 24,9 posto. Više i visoko obrazovanih među najmlađima je 17,3 posto, a najstarijima 9,8 posto. Kao što kaže Bourdieu, sposobnosti i talent rezultat su (i) “ulaganja vremena i kapitala” (Bourdieu, 1986.:244).

Preko zanimanja obrazovanje je povezano i s ekonomskim kapitalom. Medijan osobnih primanja onih s najnižim obrazovanjem je 1.400 kuna, a onih s najvišim 4.250 kuna. Slično je i s prihodom obitelji. To, dakako, nije ništa novo. Usporn meritokratskog društva u kojem su cijenjeni obrazovani profesionalci ide usporedo s razvojem industrijskog društva, pa se u razvijenim evropskim zemljama može pratiti od druge polovice 19. stoljeća (Halcli; Webster, 2000.:73). I u socijalističkoj Hrvatskoj obrazovanje je bilo jedan od najznačajnijih kanala vertikalne mobilnosti i poboljšanja životnog standarda. Digitalna nejednakost tako se opet veže uz već postojeće nejednakosti.

Razlike s obzirom na tip naselja također su rezultat razvoja modernog industrijskog društva. Hrvatska je, primjerice, 1961. godine imala 43,9 posto poljoprivrednog stanovništva, a 1991. godine, kada se raspadao socijalizam i tek je počelo širenje interneta, 9,1 posto (DZS, 1997.:87). No, izgleda da počeci kompjutorizacije u Hrvatskoj padaju upravo u 1961. godinu. U knjizi *Sjećanja* Eva Grlić, koja je tada radila u Katranu, piše kako su “zagrebačke tvornice Pliva, Chromos, OKI i Katran, udružene u Kemijsku industrijsku zajednicu sa sjedištem u Boškovićevoj ulici, kupile, mislim

1961. godine, u Hrvatskoj vjerojatno prvu garnituru elektronskih računala tvrtke IBM za strojnu obradu podataka tih udruženih poduzeća” (Grlić, 1997.:252). I ovaj detalj svjedoči da informacijsko doba nije nešto radikalno novo već je pripremano i u etatičkim zemljama i privredama koje su po Castellsu propale upravo zato jer se nisu mogle priključiti na revoluciju informacijske tehnologije.

Najmanje su razlike između korisnika interneta i onih koji internet nikad ne koriste po veličini obitelji i spolu. Štoviše, istraživanja u razvijenim zemljama pokazuju da se širenjem interneta razlika po spolu gubi, a i u Hrvatskoj je najmanja od svih analiziranih varijabli. To znači da je i patrijarhalno, kao i agrarno društvo, u razvijenim zemljama uglavnom stvar prošlosti. Pa ako se danas u tim društvima žene i muškarci sve više izjednačuju očito nema “prirodnih” razlika koje bi uvjetovale razlike u uporabi informacijsko-komunikacijskih tehnologija.

Nastojali smo pokazati da digitalna nejednakost nije neki nov, poseban oblik nejednakosti, nego da se veže uz već postojeće nejednakosti modernog društva, prije svega uz kulturni i ekonomski kapital, kako ih određuje Bourdieu. U korištenju interneta kao indikatora razvoja informacijskog doba, društvene grupe se razlikuju upravo prema količini kapitala koji posjeduju kako bi mogle “prihvatiti” i “savladati” novu tehnologiju.

“Neumreženi” su, iako čine većinu na globalnoj razini, u većini zemalja svijeta pa i u Hrvatskoj, “sa stajališta logike sustava nevažni i kao proizvođači i kao potrošači” (Castells, 2003.b:368). No, ni “umreženi” ne mogu biti mirni jer procesi isključenja iz umreženog društva djeluju i na “one pojedince i društvene kategorije koji u neprestanoj borbi za održanje pokušavaju izbjeći konačni pad na dno društva gdje jedva preživljava degradirana radna snaga i društveno onespoboljeni ljudi” (Castells, 2003.b:369). Usud isključenosti iz “vladajuće logike umrežavanja” svima lebdi nad glavom. Digitalni jaz ne samo da je uspostavljen, nego se i održava neprestanom opasnošću da se padne na dno društva. Ovako dramatičan pristup digitalnoj podijeljenosti proizlazi, kako smo naveli u uvodu, iz teorijskog modela koji sve suvremene promjene izvodi iz “vladajuće logike umrežavanja”, a informacijsko doba vidi kao “sekularno spasenje” (McSorley, 2003.:85) koje može ostvariti san prosvjetiteljstva “da će razum i znanost riješiti probleme čovječanstva” (Castells, 2003.b:382). Za ostvarenje tog sna, po Castellsu, potrebno je “preskočiti planetarnu digitalnu podjelu” (Castells, 2003.a:295). Zašto “preskočiti”? Zato jer je skok brz, zato jer nema vremena za razmatranje alternativnih modela razvoja, zato jer se novo društvo temeljeno na internetu razvija brzinom interneta. Castellsovo vrijeme, vrijeme interneta, trenutačno je vrijeme kojim financijski kapital obavlja transakcije putem interneta. No, kako pokazuju rezultati analize, vrijeme potrebno da bi se ostvarile pretpostavke potrebne za “umrežavanje” vrijeme je akumulacije kulturnog i ekonomskog kapitala, povijesno vrijeme koje se ne može sabiti u trenutak.

Političari pak očekuju da će informacijska revolucija riješiti probleme koje oni sami ne mogu – korupciju, bujanje birokracije, smanjenje troškova zdravstva, malverza-

cije u gruntovnicama i još mnogo toga. Odgovor je – neće. I to nije tako samo u Hrvatskoj. Da tehnologija može riješiti društvene probleme jedan je od mitova koji se veže (i) uz internet. “Tehnologija nije odgovor, nego alat. Ako se s njim pažljivo postupa, može značajno unaprijediti razvojne ciljeve ljudi” (Servon, 2002.:225). Digitalna nejednakost samo je jedan oblik društvenih nejednakosti i može se prevladati utoliko koliko se razvija i mijenja društvo.

Literatura

1. Batarelo, I.; Marušić, I. (2006). Digitalna podijeljenost u hrvatskim školama: razlike u korištenju računala s obzirom na neke socio-demografske varijable. *Sociologija sela*, 172–173 (2–3):201–219.
2. Bourdieu, P. (1986). U: Richardson, J. (Ed.). *Handbook of Theory and Research for the Sociology of Education*. New York: Greenwood Press, pp. 241–258.
3. Castells, M. (2000a). Materials for an exploratory theory of the network society. *British Journal of Sociology*, 51 (1):5–24.
4. Castells, M. (2000b). Toward a Sociology of the Network Society. *Contemporary Sociology*, 29 (5):693–699.
5. Castells, M. (2003a). *Internet galaksija*. Zagreb: Naklada Jesenski i Turk, 320 str.
6. Castells, M. (2003b). *Kraj tisućljeća*. Zagreb: Golden marketing, 438 str.
7. DiMaggio, P.; Hargittai, E.; Neuman, W. R.; Robinson, J. P. (2001). Social Implications of the Internet. *Annual Review of Sociology*, 27 (1):307–336.
8. Državni zavod za statistiku (1997). *Statistički ljetopis 1997*. Zagreb: DZS, 610 str.
9. Hannemyr, G. (2003). The Internet as Hyperbole: A Critical Examination of Adoption Rates. *The Information Society*, 19 (2):111–121.
10. Grlić, E. (1997). *Sjećanja*. Zagreb: Durieux, 336 str.
11. Guillén, M. F.; Suárez, S. L. (2005). Expaining the Global Digital Divide: Political and Sociological Drivers of Cross-National Internet Use. *Social Forces*, 84 (2):681–708.
12. Halcli, A.; Webster, F. (2000). Inequality and Mobilization in The Information Age. *European Journal of Social Theory*, 3 (1):67–81.
13. Hodžić, A. (2000). Socijalna struktura i mobilnost seoskog stanovništva, *Sociologija sela*, 147/148 (1/2):79–107.
14. Hodžić, A. (2005). Mreža naselja u umreženom društvu. *Sociologija sela*, 43, 169 (3):497–524.
15. ITU: International Telecommunication Union (2005). *Telecommunication/ICT statistics*. URL: <http://www.itu.int/ITU-D/ict/statistics/> (listopad 2007).
16. McSorely, K. (2003). The secular salivation story of the digital divide. *Ethics and Information Technology*, 5 (1):75–87.
17. Norris, P. (2000). *Digital Divide? Civic Engagement, Information Poverty and the Internet in Democratic Societies*. URL: <http://web.archive.org/web/20010422081248/ksg/home.harvard.edu/~pnorris.shorenstein.ksg/DIGITALR.HTM> (srpanj 2007).
18. Sanader, Dr. I. (2007). *Prema novim izazovima*. Zagreb: Hrvatska demokratska zajednica, 47 str.
19. Servon, L. (2002). Four Myths about the Digital Divide. *Planning Theory & Practice*, 3 (2):222–227.
20. Van Dijk, J. (1999). The one-dimensional network society of Manuel Castells. *New Media and Society*, 1 (1):127–138.

21. Van Dijk, J.; Hacker, K. (2003). The Digital Divide as a Complex and Dynamic Phenomenon. *The Information Society*, 19 (4):315–326.
22. Webster, F. (2002). *Theories of the Information Society*. New York: Routledge, 304 str.
23. Župančić, M. (2000). Tranzicija i modernizacijske perspektive hrvatskih sela, *Sociologija sela*, 147/148 (1/2):11–78.

Branimir Krištofić

Institute for Social Research in Zagreb, Zagreb, Croatia

e-mail: kristof@idi.hr

Digital Inequality

Abstract

The paper analyses global use of information-communication technology based on data provided by the International Telecommunication Union; in Croatia data are obtained from field research carried out by the Institute for Social Research in Zagreb on a representative sample of adult population of Croatia. In telephones, mobile phones and the Internet Croatia equals the European average, while it falls behind in the number of computers per one hundred inhabitants. In Croatia, digital inequality is best predicted by both education and income of a household, that is, personal income of examinees. The Internet users are better educated and have a higher income than those who never use it. Statistically relevant differences relate to age and place of living, minor differences to gender. The Internet users are young people mostly living in towns, there are slightly more men than women among them. The Internet is mostly used in families with three or four members. Already existing social inequality correlates with digital inequality. Therefore the digital gap, an essential form of information era inequality (Castells), can be bridged only by decreasing social inequality.

Key words: digital divide, digital inequality, social inequality, Internet, Information Age, Manuel Castells.

Received on: October 2007

Accepted on: October 2007