1. PODACI

U uvodnom se poglavlju opisuju osnovni pojmovi: pojam ili koncept, podatak, informacija ili obavijest, znanje i mudrost. Uočava se da se pomoću podataka zapisuju i memoriraju činjenice. Pročita li se i protumači podatak ili skup podataka, dobiva se informacija, odnosno obavijest. Ako se usto primjenjuje ekspertno mišljenje, vještina ili iskustvo, govori se o znanju. Na kraju je mudrost koja „zna“ kada i kako upotrijebiti znanje za određenu svrhu. U poslovanju se podaci i informacije smatraju važnim resursom. Utoliko je važnije da su informacije kvalitetne. Kvaliteta informacije je skupna karakteristika koja se može raščlaniti na niz specifičnih karakteristika, kao što su točnost ili ispravnost. Vrijednost informacije razmjerno je teško utvrditi jer ona ovisi o korisniku i svrsi korištenja.

1.1. Uvod

Bez podataka bi bilo nemoguće poslovati. U poslovanju se evidentiraju podaci o nizu elemenata poslovanja, kao što su nazivi i adrese poslovnih partnera ili klijenata, stanja gotovih proizvoda i sirovina u skladištima, količina naručene i prodane robe, izdani i primljeni računi itd. U specifičnim je primjenama vođenje poslovnih podataka i zakonski uređeno. Primjerice zakonom je određen način vođenja matičnih podataka građana ili trgovačkih društava. U poslovanju susrećemo niz manje ili više unificiranih dokumenata na kojima su zapisani podaci o obavljenoj prodaji, odnosno kupnji (račun), primitku robe u skladište (primka), ulasku na predstavu (ulaznica), dosad položenim ispitima (indeks), potvrdi o završenoj školi (svjedodžba), popisu jela koji se nude u restoranu (jelovnik), itd. Lako je zaključiti da podaci obavještavaju (informiraju) o nekom konkretnom aspektu poslovanja.

Podatke zapisujemo na tradicionalne medije kao što su papir ili film, a danas sve češće na elektroničke medije na kojima se ostvaruju široke mogućnosti suvremene elektroničke, odnosno informatičke obrade podataka. Za razumijevanje suvremene obrade podataka potrebno je razmotriti pojmove koji će omogućiti predstavljanje stvarnog svijeta jezikom podataka. Podacima ćemo se služiti da izgradimo podatkovni ili informacijski sustav koji će pomoći da se podacima podupre poslovanje. Pritom je potreban model koji će pomoću podataka moći opisati i obrađivati stvarni svijet koji nas okružuje, a koji se služi pojmovima *pojam*, *podatak*, *informacija*, *znanje* i *mudrost*.

1.2. Pojam ili koncept

Ljudi imaju sposobnost stvaranja i razlikovanja pojmova (koncepata), spoznajnih jedinica kojima se služe u spoznaji svijeta. Na određen način to su „jedinice znanja“. Pojam je predodžba o nekoj „stvari“ svijeta. Da bi mogli međusobno komunicirati pojmovima, ljudi ih reprezentiraju simbolima, primjerice to su riječi jezika kojim

www.element.hr

komuniciraju. Svima je poznat pojam *knjige*, „stvari“ u kojoj su zapisani tekstovi i ilustracije, ili pojam *dobar* koji vezujemo uz dobre osobine nečega što promatramo. Kombinirajući jednostavne pojmove, možemo graditi i nove, primjerice *dobra knjiga*. *Knjiga*, *dobar* i *dobra knjiga* primjeri su pojmova ili koncepata, pa zaključimo: *pojam* ili *koncept* jest ideja, odnosno predodžba u našoj svijesti koju primjenjujemo na određenu „stvar“ iz stvarnog svijeta.

U informatičkoj se teoriji i praksi, koja se bavi izgradnjom „sustava podataka“, često služimo terminom *objekt*. Objekt je bilo što na što se može primijeniti pojam, odnosno koncept. On je instanca, odnosno pojava koncepta (Martin i dr., 1995). Možemo reći da sve o čemu pojmimo, na što se referiramo ili što opisujemo jest *objekt* tako dugo dok imamo *pojam* uz koji ga vezujemo. Primjerice moramo imati pojam *posao* da bismo mogli definirati i zapisati različite vrste (instance ili pojave) poslova.

1.3. Podatak

Da bismo komunicirali i zapisali pojmove služimo se *podacima*. Spomenuti pojam *knjige* prikazujemo znakovima **knjiga** ako se služimo hrvatskim, **the book** engleskim, a **das Buch** njemačkim jezikom. Možemo se koristiti i znakom ili sličicom 🕮.

Podatak – osnovni pojam u ovoj knjizi – skup je prepoznatljivih *znakova,* odnosno simbola zapisanih na nekom mediju, npr. papiru, filmu, magnetskom ili kojem drugom mediju. Pomoću podataka zapisujemo činjenice, pritom ne razmatramo ni njihovu interpretaciju ni njihov kontekst.

Tijekom života naučili smo niz skupova znakova kojima se koristimo u poznatim primjenama. Oni služe kao tehničko sredstvo da bismo zapisali podatke. Evo nekoliko primjera:

- Znakovima abecede **A**, **a**, **B**, **b**, **C**, **c** itd. služimo se pri zapisivanju govora.
- Znakovima ♢, ♧, ✦ i ♣ označujemo „boje“ u kartaškim igrama, koje u govornom obliku zapisujemo kao karo, herc, pik, tref.
- U prometu se služimo prometnim znakovima.
- U stručnim primjenama služimo se specifičnim znakovima (npr. u matematici: $+, -, /, <, =, >, \Pi, \Sigma, \perp, \int$, itd.).

Naš stvarni (poslovni) svijet opisujemo odabranim pojmovima, a zapisujemo ih podacima. U informatici se najjednostavniji *elementarni podatak* vezuje uz prikaz (zapis) jednog obilježja određenog objekta. Npr. podatak **Ivan** prikazuje obilježje imena jedne osobe.

Većina poslovnih aktivnosti popraćena je podacima. U poslovanju vrijedi pravilo „što podacima nije zabilježeno, nije se ni dogodilo“. Posljedično, rezultati se poslovnih događaja zapisuju zapisima (podataka) u nekoj „bazi podataka“. Tako svaki posao postaje ujedno i podatkovni (informacijski) posao.

Moderna informacijska tehnologija sposobna je većinu podataka zabilježiti u digitalnom obliku, pogodnom za automatiziranu obradu. Kako se podaci generiraju

www.Element.hr

u digitalnom obliku, to silno umnaža njihovu količinu. Trend povećanja količine podataka nastavit će se i u budućnosti, što će dovoditi do preplavljenosti podacima (i informacijama). Pitanje je kako se optimalno koristiti dostupnim podacima (i informacijama).

1.4. Informacija

Informacija ili *obavijest* nastaje tumačenjem, odnosno interpretacijom podataka i stavljanjem u kontekst značenja. Dakle, protumačeni podatak donosi informaciju. Kao što pokazuje slika 1.1, podatke je katkad potrebno transformirati (selektirati, klasificirati, sortirati, agregirati ili na koji drugi način obraditi), a zatim protumačiti da bismo dobili informaciju.

Slika 1.1. Transformiranje/interpretacija podataka u informacije

Protumačeni elementarni podatak daje *elementarnu informaciju*. Elementarna informacija odnosi se na n-torku *<objekt, obilježje objekta, vrijeme, vrijednost obilježja>*. Primjerice vrijednost 7,45 može biti protumačena ovako: objekt je tečajna lista, obilježje objekta je odnos euro/kuna, vrijednost obilježja je 7,45, a vrijeme je 3.1.2010. Elementarna informacija *„3.1.2010. odnos euro/kuna jest 7,45*" ujedno predstavlja i *elementarnu poruku*.

Obrnuto, kako zapisati informaciju na mediju? Hoće li na mediju biti zabilježena n--torka *<objekt, obilježje objekta, vrijeme, vrijednost obilježja>* upravo u spomenutom obliku ili nekako drugačije, ovisi o upotrijebljenom modelu zapisa podataka u „sustavu podataka", odnosno *informacijskom sustavu*, o čemu će biti riječi u knjizi.

Informacija, odnosno *obavijest* jest dakle činjenica s određenim značenjem. Ona donosi novost, obavještava o nečemu, otklanja neizvjesnost i općenito služi kao podloga za odlučivanje. Temeljna je svrha informacije da pomogne pri donošenju odluke, jer bez kvalitetne informacije o predmetu odlučivanja malo je vjerojatno da se može donijeti dobra odluka. Uloga informacija u procesu odlučivanja opisana je u poglavlju 3.5.

Zbog svoje važnosti u poslovanju, podaci i informacije smatraju se važnim resursom, odnosno *imovinom* prijeko potrebnom u modernom poslovanju – govori se o informacijskoj imovini (engl. *information asset*).

1.4.1. Kvaliteta informacije

Kvaliteta informacije je, kao i kod svih drugih roba, skupna karakteristika. Literatura (Bocij i dr., 2006) navodi niz popisa karakteristika kvalitetne informacije koje se odnose na karakteristike vremena (pravovremenost, usklađenost sa stvarnim stanjem, učestalost, vremenski period), sadržaja (točnost, primjerenost, kompletnost, konciznost, opseg), količine, forme (jasnoća, detaljnost, redoslijed,

prikaz, medij), kao i na druge o kojima trebaju voditi računa projektanti informacijskog sustava. Primjerice krajnji korisnici informacija trebaju kvalitetne informacije u količini dostatnoj za odlučivanje, a prevelika količina informacija može im otežati postupak odlučivanja.

Kvaliteta podataka usmjerena je na točnost, ispravnost i urednost podataka. Budući da se u modernom poslovanju podaci pohranjuju u računalne baze podataka, kvaliteta podataka prije svega pripada tehnološkoj informatičkoj problematici. Nasuprot tomu, *kvaliteta informacija* usmjerena je na poslovnu i upotrebnu problematiku jer se upotrebljivost informacija očituje pri poslovnom odlučivanju. Dakle, kvaliteta informacija pripada poslovnoj, a kvaliteta podataka informatičkoj domeni, iako se obje kvalitete mjere ili ocjenjuju vrlo slično.

Kahn i dr. (2002) navode da se kvaliteta informacija, odnosno podataka opisuje na četiri načina: kao izvrsnost, kao vrijednost, kao usklađenost sa specifikacijama i kao podudarnost s očekivanjima korisnika. Definiranje kvalitete pojmom izvrsnosti previše je subjektivno, a pojmom vrijednosti nije dostatno jer ne uzima u obzir ostale komponente kvalitete. Stoga preostaju dva načina opisa kvalitete koji kažu da je kvaliteta informacija, odnosno podataka mjera koja opisuje:

- *koliko informacija, odnosno podatak ispunjava očekivanja korisnika, ili*
- *koliko udovoljava zahtjevima ili specifikacijama kvalitete.*

U tablici 1.1 navedene su najčešće korištene karakteristike kvalitete (Kahn i dr., 2002; Pipino i dr., 2002) na hrvatskom i engleskom jeziku. One su jednake za informacije i za podatke.

Karakteristike kvalitete informacije	Koliko je informacija ...
dostupnost/accessibility	… dostupna
dostatnost/appropriate amount	… količinski odgovarajuća
uvjerljivost/believability	… istinita i kredibilna
potpunost/completeness	… potpuna
jezgrovitost/concise representation	… jezgrovita, kompaktna, koncizna
konzistentnost/consistent representation	… konzistentno prezentirana
jednostavnost/ease of manipulation	… jednostavna za korištenje
točnost/free-of-error	… točna (korektna , pouzdana)
interpretabilnost/interpretability	… odgovarajuće prikazana (jedinicama …)
objektivnost/objectivity	… nepristrana, objektivna
relevantnost/relevancy	… relevantna, primjerena, odgovarajuća
reputacija/reputation	… „časna“ u odnosu na izvor i sadržaj
sigurnost/security	… zaštićena od neovlaštenog pristupa
pravovremenost/timeliness	… pravovremena, ažurna
razumljivost/understandability	… razumljiva
dodana vrijednost/value-added	… korisna (daje novu vrijednost)

Tablica 1.1. Karakteristike kvalitete informacije

www.element.hr

U jednostavnijem razmatranju dovoljno je reći da je kvalitetna informacija *točna*, *potpuna*, *primjerena* (relevantna) i *pravovremena*, tj. kvalitetna informacija ima ove karakteristike:

- *Točnost* – Informacija je točna ako korektno opisuje stvarno stanje. Informacijski sustav trebao bi nuditi točne informacije. Ako nije tako, reputacija informacijskog sustava bit će loša. Pristupamo li prvi put nekom izvoru informacija (npr. informacijskom sustavu ili internetu), poželjno je imati određenu dozu sumnje, dok se provjerom ponuđenih informacija ne uvjerimo da su one točne.
- *Potpunost* – Informacija je potpuna ako potpuno opisuje stvarno stanje i ako se opisu nema što dodati. Potpuna informacija je i objektivna informacija jer ne sakriva nepovoljne činjenice. Potpunost informacija može se ustanoviti provjerom više izvora informacija.
- *Primjerenost* (relevantnost) – Informacija je primjerena (relevantna) ako odgovara kontekstu i osobi koja je prima. Primjerice osobi koju zanimaju prosječni troškovi po jedinici proizvoda u nekom vremenskom periodu informacija o svim pojedinačnim troškovima svih proizvoda kroz nekoliko mjeseci ne mora biti primjerena.
- *Pravovremenost* – Informacija je pravovremena ako je dobivena na vrijeme. Mjesečni izvještaj koji je kasnio može biti beskoristan, a onaj načinjen na vrijeme može imati veliku vrijednost.

Da bi bile upotrebljive, karakteristike moraju biti mjerljive uz razuman trud, i stoga ih možemo nazvati i *mjerama* kvalitete. Trebaju biti razumljive s minimalnom dodatnom interpretacijom, takve da se mogu međusobno kombinirati u agregatne mjere. Trebaju biti jednake za sva poslovna, zemljopisna ili organizacijska područja u kojima se primjenjuju, te primjenljive unutar i izvan organizacije. Moraju biti u mogućnosti utjecati na poboljšanje kvalitete informacija. Karakteristike, navedene u tablici 1.1, uglavnom imaju ova svojstva. Nažalost, način primjene ovih mjera nije standardiziran.

Upotrebljivost šireg popisa karakteristika informacija, prikazanog tablicom 1.1, pogodno je razmotriti kroz model kvalitete informacija (Kahn i dr., 2002) prikazan u tablici 1.2. Pojedine karakteristike kvalitete pridijeljene su kvadrantima modela, arbitrarno anketiranjem informacijskih profesionalaca. Pritom je postignuta velika suglasnost klasificiranja karakteristika, s izuzetkom nešto manjeg slaganja kod karakteristika interpretabilnosti i objektivnosti.

Lijevi stupac tablice 1.2 opisuje karakteristike kvalitete informacije koje pokazuju koliko informacija udovoljava zadanoj specifikaciji, a desni stupac opisuje karakteristike koje pokazuju koliko informacija udovoljava postavljenim očekivanjima korisnika. Specifikacije općenito omogućuju precizno mjerenje zadovoljava li mjereni proizvod ili usluga zadani prag kvalitete. Takav način mjerenja kvalitete više će odgovarati proizvođačima i skrbnicima informacija, odnosno podataka, a manje krajnjim korisnicima informacija. Kvalitetna informacija mora ispuniti ili nadmašiti njihova očekivanja i donijeti im novu vrijednost pri odlučivanju ili izvršenju zadatka. Korisnicima informacija će prema

tome više odgovarati ocjenjivanje kvalitete informacija karakteristikama u desnom stupcu.

	Koliko kvaliteta udovoljava specifikacijama (standardima)	Koliko kvaliteta udovoljava očekivanjima korisnika
Kvaliteta informacije kao proizvoda	***Ispravnost informacije:*** **točnost** **jezgrovitost** **potpunost** **konzistentnost**	***Korisnost informacije:*** **dostatnost** **relevantnost** **razumljivost** **interpretabilnost** **objektivnost**
Kvaliteta informacije kao usluge	***Pouzdanost informacije:*** (koliko proces pretvaranja podataka u informaciju udovoljava specifikacijama) **pravovremenost** **sigurnost**	***Upotrebljivost informacije:*** (koliko proces pretvaranja podataka u informaciju udovoljava očekivanjima) **uvjerljivost** **dostupnost** **jednostavnost korištenja** **reputacija** **dodana vrijednost**

Tablica 1.2. Aspekti modela kvalitete informacije ili podataka

U gornjem retku tablice 1.2 nalaze se karakteristike kvalitete koje odgovaraju promatranju informacija i podataka kao proizvoda, a u donjem retku kao usluge. Podatak osobito možemo smatrati proizvodom koji je proizveden, spremljen i spreman za korištenje te ima opipljive karakteristike. Takve su karakteristike točnost i potpunost. Informacija se, naprotiv, može smatrati uslugom. Proizvedena od podataka i pritom konzumirana, informacija daje dojam usluge jer uključuje interakciju sustava i korisnika. Podaci su u sustavu dakle proizvod, a njihovom obradom nastaju informacije kao usluge. Primjerice aplikacija koja od podataka oblikuje informativni grafički prikaz daje uslugu u vidu informacija. Kvaliteta informacije opisuje i latentne karakteristike podataka kao proizvoda koje postaju vidljive nakon pretvorbe podataka u informacije, bilo one vizualne bilo koje druge. Valja naglasiti da su tipični proizvodi uobičajeno opipljivi, a usluge neopipljive. Međutim, pri promatranju informacija ili podataka to ipak ne treba shvaćati potpuno doslovno.

Klasificiranje pojedinih karakteristika po kvadrantima, prema načinu gledanja na informaciju (kao proizvod ili kao uslugu) i načinu mjerenja njezine kvalitete (udovoljava li postavljenim specifikacijama ili udovoljava očekivanjima korisnika), pomaže prije svega proizvođačima i skrbnicima informacija da bolje razumiju kako informaciju učiniti kvalitetnom. Razmotrimo primjenu modela:

- *Ispravnost informacija*: U kvadrantu ispravnosti informacija promatraju se karakteristike (točnost, jezgrovitost, potpunost i konzistentnost) koje opisuju koliko informacija promatrana kao proizvod udovoljava specifikacijama kvalitete. Ovim se karakteristikama najbolje mjeri kvaliteta podataka u bazi podataka informacijskog sustava jer se ispravnost informacije temelji na ispravnim podacima. Karakteristike iz ovog kvadranta opipljive su i mjerljive u odnosu na postavljene specifikacije. Moguće ih je ocijeniti temeljem samih

www.element.hr

podataka iz baze podataka. Ispravnost podataka ili informacija uglavnom ne ovisi o zadatku i odluci koje korisnik donosi temeljem informacije. Korisniku je važno da informacija bude točna, bez pogrešaka i dobro prezentirana. Informacija mora biti potpuna jer nepotpuna informacija može dovesti do pogrešne odluke. Konzistentna informacija pak osigurava zadovoljavajući stupanj interpretabilnosti i razumljivosti informacije.

- *Pouzdanost informacija*: U kvadrantu pouzdanosti informacija promatraju se karakteristike (pravovremenost, sigurnost) koje opisuju koliko informacija promatrana kao usluga udovoljava specifikacijama kvalitete. Informacija kao usluga nastaje u procesu njezina prihvaćanja i korištenja. Primjerice ako korisnik dobiva informaciju uvijek pravovremeno, u zadanom roku, tada je specifikacija usluge zadovoljena, odnosno ispunjena. Karakteristike iz ovog kvadranta ne mogu *a priori* biti ocijenjene temeljem samih podataka iz baze podataka. Kao kod svake usluge, kvaliteta informacije može se ocijeniti tek nakon njezine upotrebe.
- *Korisnost informacija*: U kvadrantu korisnosti informacija promatraju se karakteristike (dostatnost, relevantnost, razumljivost, interpretabilnost, objektivnost) koje opisuju koliko informacija promatrana kao proizvod udovoljava očekivanjima korisnika, odnosno koliko mu je ona korisna. Ocjenjivanje karakteristika iz ovog kvadranta povezano je sa zadatkom koji korisnik obavlja. Je li informacija relevantna ovisi o zadatku koji korisnik obavlja. Informacija je dostatna ako omogućuje odlučivanje.
- *Upotrebljivost informacija*: U kvadrantu upotrebljivosti informacija promatraju se karakteristike (uvjerljivost, dostupnost, jednostavnost korištenja, reputacija, dodana vrijednost) koje opisuju koliko informacija promatrana kao usluga udovoljava očekivanjima korisnika. Primjerice ako korisnici imaju mogućnost odgovarajućim programskim alatom dostupiti do podataka kako bi dobili informacije za efikasno odlučivanje, korisnost je podataka ili informacija veća. Pomoću karakteristika iz ovog kvadranta može se razlikovati jedna usluga od druge, uvažavajući korisnički pogled na problem. Da bi iskoristio informaciju, korisnik mora biti u mogućnosti pristupiti joj i prilagoditi je svojim potrebama. Stoga ove karakteristike ovise o informacijskom sustavu kao posredniku između korisnika i podataka, a koji omogućuje pristup i prilagodbu informacija. Korisnik će se koristiti informacijom ako mu je dostupna i ako je jednostavnog korištenja, i pritom uvjerljiva i s dovoljno reputacije.

U praksi se najviše pažnje posvećuje karakteristikama u kvadrantu ispravnosti informacija, gdje se na informaciju gleda kao na proizvod koji udovoljava postavljenim specifikacijama. Te karakteristike najlakše je definirati i mjeriti. Služba koja upravlja informacijskim sustavom lako će definirati specifikacije kvalitete podataka u bazi podataka, način njihova prikupljanja, pohranjivanja i održavanja. Sustavi za upravljanje bazama podataka imaju niz mogućnosti, iako ne sve, da podatke održavaju kvalitetnima. Kontrole održavanja entitetskog i referencijskog integriteta u sustavima za upravljanje bazama podataka primjeri su funkcija za održavanje kvalitete podataka. Alatima za profiliranje podataka može se dodatno provjeravati kvaliteta.

Da bi se isporučile pouzdane informacije koje udovoljavaju specifikacijama iz kvadranta pouzdanosti, potrebno je na informaciju gledati kao na uslugu koja se treba isporučiti pravovremeno i sigurno.

Informaciju koja udovoljava karakteristikama iz kvadranta korisnosti, gdje informacija treba udovoljavati očekivanjima korisnika, teže je osigurati jer je očekivanja korisnika teže odrediti, ona se s vremenom mijenjaju, kako zbog promjena u poslovanju tako i zbog tehnološkog napretka.

Da bi informacija udovoljavala karakteristikama iz kvadranta upotrebljivosti, nužno je korisnicima osigurati dostup do informacija, omogućiti jednostavnost korištenja, uvjerljivost i reputaciju informacija te ostvariti dodanu vrijednost. Korisnicima to omogućuju snažni alati za pretraživanje i analizu podataka koji su opremljeni jednostavnim i intuitivnim sučeljima.

Treba li mjeriti sve karakteristike informacije ili samo neke? U području mjerenja kvalitete informacija i podataka još nema čvrstih normi ili definirane najbolje prakse. Stoga svaka organizacija koja želi mjeriti kvalitetu svojih informacija ili podataka mora sama odlučiti koje će karakteristike kvalitete mjeriti i kako će ih mjeriti. Mjerenje kvalitete služi da se ocijeni sadašnja kvaliteta informacija ili podataka i da se nakon ocjene mogu poduzeti mjere unapređenja kvalitete. Kvaliteta informacija može se unaprijediti jednokratno kroz *projekt unapređenja kvalitete informacija* s jasno definiranim ciljevima, optimalno određenim karakteristikama kvalitete koje će se mjeriti i definiranim načinima mjerenja ili ocjene kvalitete. Projekt treba završiti preporukama za unapređenje kvalitete informacija. Za trajno praćenje i unapređenje kvalitete informacija poželjno je organizirati *sustav za upravljanje kvalitetom informacija*.

Kvaliteta informacije može se ocijeniti na subjektivan način ili mjeriti na objektivan način. Svakako je bolje mjeriti objektivno nego ocjenjivati subjektivno. Međutim, za takvo mjerenje prikladne su uglavnom karakteristike kvalitete u kojima se informacija doživljava kao proizvod. Kada se informacija promatra kao usluga, kvalitetu informacije uglavnom je moguće ocijeniti kroz subjektivan doživljaj. Bez obzira kako se mjeri informacija, objektivno ili subjektivno, potrebno je utvrditi metriku pojedinih karakteristika.

Metrika objektivnog mjerenja kvalitete informacija gledane kao proizvod, a takve su karakteristike točnosti, konzistentnosti, jezgrovitosti ili relevantnosti, treba mjeriti odnos broja kvalitetnih informacija u odnosu na broj svih informacija. Mjera treba biti izražena u postotku ili na skali od 0 do 1, gdje 1 ili 100% znači potpuno kvalitetnu informaciju, a 0 ili 0% potpuno nekvalitetnu informaciju.

Subjektivno ocjenjivanje provode sami korisnici na anketni način ocjenjujući svoj subjektivni doživljaj promatrane karakteristike kvalitete. Takvo je ocjenjivanje prikladno za ocjenjivanje karakteristika koje opisuju informaciju kao uslugu. Metrika subjektivnog ocjenjivanja treba biti na istoj skali, najbolje od 0 do 1, kao i kod objektivnog mjerenja. Na taj se način različite karakteristike mogu međusobno uspoređivati. Ako je riječ samo o subjektivnom ocjenjivanju, može se koristiti Likertovom skalom koja mjeri stav, preferenciju ili subjektivno mišljenje na skali od 1 do 5, 7 ili 9, gdje 1 odgovara najlošijoj kvaliteti („uopće se ne slažem da je

informacija kvalitetna“), 3 odgovara srednjoj kvaliteti („neutralan sam“) ili 5 koja odgovara najvišoj kvaliteti („potpuno se slažem da je informacija kvalitetna“).

Iako je objektivno mjerenje prikladno za mjerenje karakteristika koje odgovaraju informaciji kao proizvodu, a subjektivno za mjerenje karakteristika koje odgovaraju informaciji kao usluzi, ipak se istovremeno može izvesti subjektivno ocjenjivanje i objektivno mjerenje za istu karakteristiku. Time se može procijeniti koliko se subjektivna ocjena kvalitete razlikuje od objektivne mjere. Ako se ona bitno razlikuje, potrebno je utvrditi uzroke dobivenih razlika te odrediti mjere za njihovo uklanjanje.

Mjerenje se, odnosno ocjenjivanje, radi za svaku pojedinu karakteristiku kvalitete, a za karakteristike koje pripadaju pojedinom kvadrantu može se odrediti prosječna mjera, odnosno ocjena. Njima se može koristiti za usporedbu kvalitete informacija između organizacija pojedinih djelatnosti ili za usporedbu kvalitete informacija iste organizacije u različitim trenucima.

1.4.2. Vrijednost informacije

Već je rečeno da podatak prezentiran u kontekstu značenja čini informaciju (Kroenke, 2007). Što je kontekst značenja za primatelja informacije? On ne mora biti jednak za sve primatelje. Primjerice podaci o količini i vrijednosti prodaje jedne vrste proizvoda jednog određenog dana u jednoj prodavaonici bitni su za poslovođu prodavaonice. Međutim, brend menadžeru bitni su podaci količine i vrijednosti prodaje te vrste proizvoda u svim prodavaonicama zajedno, a šefu prodaje ti isti podaci čine samo jednu stavku podataka u ukupnom dnevnom zbroju prodaje svih proizvoda u svim prodavaonicama. Ukupna dnevna prodaja samo je jedan od podataka koji višem menadžeru služi za dobivanje (izračunavanje) informacije o isplativosti prodaje promatrane vrste proizvoda. To pokazuje da je kontekst značenja informacija različit i da ovisi o interesu primatelja informacije. Iskustvo različitosti konteksta značenja vjerojatno smo svi doživjeli nakon što je reakcija okoline na naše uzbuđeno izvještavanje nama bitne informacije bilo mlakog oblika „pa što onda“.

Informacija daje podlogu za odlučivanje pa se može očekivati da će donositelj odluke temeljem kvalitetnije informacije donijeti bolju odluku. Upotrebna vrijednost informacije ovisi o njezinoj daljnjoj upotrebi u „lancu“ vrijednosti, preciznije o tome koliki je doprinos informacije pri donošenju odluke. To se može opisati sljedećom formulom:

$$VI = RA - RB$$

gdje je *RA* vrijednost rezultata odluke donesen temeljem informacije, a *RB* vrijednost rezultata odluke koji nije temeljen na informaciji. Rezultat se mjeri u novčanim jedinicama, primjerice u kunama. Prema tome, vrijednost informacije *VI* jest dodana vrijednost nastala u odlučivanju koja je ostvarena temeljem promatrane informacije.

U praksi je stvarnu vrijednost informacije teško odrediti. Da bi informacija imala upotrebnu, pozitivnu vrijednost, mora posjedovati kvalitetu (točnost, potpunost, primjerenost, pravovremenost…) koja će rezultirati dobrom odlukom. Nekvalitetna

informacija, netočna, odnosno lažna, može imati i negativnu vrijednost jer može prouzročiti štetu u poslovanju.

Informacija se može smatrati imovinom. Njezinu su vrijednost autori pokušavali odrediti i na druge načine, dijelom i zbog specifičnosti informacije u odnosu na druge vrste imovine. Informacija postoji samo u ljudskoj percepciji pa dijeljenjem ne gubi vrijednost. Vrijednost raste upotrebom, a opada s vremenom, raste s preciznošću, povećava se kombiniranjem s drugim informacijama. Informacija nije iscrpljiva, a više informacija nije nužno bolje (Moody i dr., 1999).

Kako pravovremenost, kao karakteristika kvalitete informacija, utječe na vrijednost informacije? Informacija je u području *prognoziranja* ako je dobivena prije nego što je potrebno donijeti odluku. Tada je njezina vrijednost najveća. Ako je dobivena u trenutku donošenja odluke, tada je u području *stvarnog vremena* i ima postojanu vrijednost. Ako je dobivena prekasno, tada je u području *zastarijevanja*, a njezina vrijednost pada. Za upravljanje je najvrednija informacija u području prognoziranja.

Vrijednost informacije raste s njezinom upotrebom. Njezina je vrijednost u korištenju, ne u posjedovanju. Što se više korisnika njome koristi, to je informacija vrednija. Temeljem toga Liautaud (2001) sugerira formulu i uočava nekoliko karakterističnih zona korištenja podacima u organizacijama, prikazanih slikom 1.2:

$$Vrijednost\ informacije = broj\ korisnika^2 \times broj\ poslovnih\ područja$$

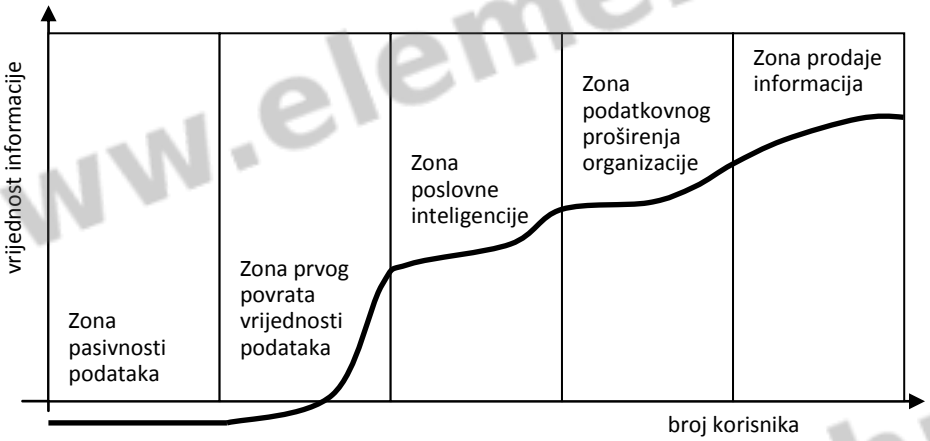

Slika 1.2. Krivulja vrijednosti informacije

Podaci se u *zoni pasivnosti* rijetko upotrebljavaju, predstavljaju trošak za organizaciju i ne smatraju se „aktivom“ organizacije. Vrijednost podataka manja je od troškova njihova održavanja. Informatičko osoblje najčešće je jedini korisnik podataka. U transakcijskim sustavima takva je većina podataka.

Prelaskom iz „pasive“ u „aktivu“ podaci prelaze u zonu *prvog povrata vrijednosti*. Poslovni korisnici počinju koristiti podatke o svojim poslovnim aktivnostima, primjerice služba ljudskih potencijala počinje koristiti podatke o plaćama, analizirajući zaposlenike po odjelima ili starosnoj dobi; ili trgovci počinju analizirati

www.element.hr

podatke o interakcijama s klijentima. Kako raste broj korisnika podataka, počinje rasti vrijednost koja postupno premašuje troškove održavanja podataka. Korisnici bolje razumiju svoje podatke i kroz njih otkrivaju ponašanje poslovnih pojava u svojem djelokrugu rada. Na taj se način uvodi odjelna poslovna inteligencija.

U sljedećem koraku odjelni se podaci otvaraju i korisnicima iz drugih odjela. To donosi novu vrijednost podacima jer ih novi korisnici promatraju i analiziraju iz drugog ugla. Primjerice ako podaci servisne službe o reklamacijama na kvalitetu ili kvarove prodanih proizvoda i odgovorima servisne službe na primljene reklamacije, podaci o problemima u korištenju kupljenim proizvodima i zadovoljstvu u radu s proizvodima postanu dostupni i otvoreni za korištenje i analizu trgovcima zastupnicima koji obrađuju kupce, kvaliteta njihova odnosa prema kupcima vjerojatno će porasti. Vrijednost podataka raste otvaranjem podataka novim korisnicima iz organizacije. Ako se podacima jednog odjela koristi i u drugim odjelima ili čitavoj organizaciji te ako se njima korisnici koriste za kvalitetnije poslovanje, oni ulaze u pravu *zonu poslovne inteligencije*, gdje se poslovna inteligencija primjenjuje na razini čitave organizacije, a ne samo jednog odjela. Nastaje stanje informacijske demokracije gdje se kolektivna poslovna inteligencija ostvaruje kroz otvorenu komunikaciju i pripravnost za dijeljenjem informacija.

Međutim, i dalje postoje mogućnosti dobivanja novih vrijednosti iz podataka ako se podacima počnu koristiti vanjski korisnici, kao što su kupci, dobavljači, poslovni partneri. Primjerice ako kupac preko ekstraneta pristupa povijesnim podacima prodaje, uvijek će imati tekuće podatke o tome što je i kada kupio, podatke o stanjima na svom računu itd. Svako širenje podataka izvan granica organizacije prema kupcima, dobavljačima ili partnerima donosi novu vrijednost podataka. Organizacija ulazi u *zonu podatkovnog proširenja organizacije*.

U *zoni prodaje informacija* organizacija može dio svojih podataka staviti na tržište kao novi proizvod, odnosno uslugu. Primjerice podaci o prodaji mogu se ponuditi novim kupcima, a agregirani depersonalizirani podaci mogu se prodati marketinškoj agenciji koja se bavi istraživanjem tržišta ili marketinškim kampanjama. Inovativne organizacije mogu svoje podatke, prikladno obrađene, ponuditi tržištu te ostvariti vrijednost koja prelazi troškove održavanja podataka.

Informacija nikad nije besplatna. Tvorci informacijskog sustava moraju pažljivo utvrditi odnos između vrijednosti informacija i troškova njezine proizvodnje. Ako se informacija smatra proizvodom informacijskog sustava, neracionalno je da informacijski sustav „proizvodi“ informacije čiji su troškovi „proizvodnje“ veći od njezine vrijednosti.

1.5. Znanje

Znanje je kombinacija podataka i informacija kojemu je dodano ekspertno mišljenje, vještina i iskustvo. Ono je vrijedna „imovina“, neophodna pri odlučivanju. Znanje može biti *eksplicitno* ili kodificirano, ako znamo kako ga opisati i zapisati, ali može

www.element.hr