

Tehnoloģiskie risinājumi interneta meklētājiem

GINTS ERNESTSONS

Informācijas meklējumiem internetā Latvijas datorlietotāji šobrīd var izmantot veselu virkni dažādu meklētājservisu. Populākie no tiem Latvijā ir Lursoft (www.lursoft.lv) un Apollo (www.apollo.lv) portālu izmantotais SIETS.LV meklētājs (www.siets.lv), kā arī portāla TvNet (www.tvnet.lv) izmantotais LATNET meklētājs. Salīdzinoši nesen sākuši darboties arī Delfi SMART (smart.delfi.lv) un Tildes LETONIKA (www.letonika.lv) interneta resursu meklētāji. Pasaulē pazistamākie interneta meklētāji ir Google (www.google.com) un Yahoo (www.yahoo.com), tagad tiem pievienojies arī Microsoft MSN meklētājs (www.msn.com).

Neskatos uz visai askētisko lietotāju interfeisu, šo serveru lietotāju skaits ir pārsteidzoši liels. Tomēr šis pieticīgais interfeiss ir visai mānīgs. Tas ir kā aisberga redzamā daļa un patiesībā tehnoloģiskais risinājums jebkurai šādai sistēmai nebūt nav trivīls.

IZAICINĀJUMI INTERNETA MEKLĒTĀJU VEIDOTĀJIEM

Veidojot interneta meklētājprogrammatūru tehnoloģiskos risinājumus, pirmā problēma, ar kuru nākas saskarties, ir lie-lais nestukturēto datu apjoms. Interneta publicētās informācijas indekss pat nelielas valsts ietvaros var aizņemt simtus gigabaitu, nereti – vairākus terabajtus. Tradicio-nālās uz SQL relāciju datu bāzēm bāzētas sistēmas nav piemērotas nestukturētu datu ātrai apstrādei, kas ir obligāts priekšno-teikums kvalitatīvam meklēšanas pakalpo-jumam.

Otra problēma ir risinājuma tehnisko līdzekļu izmaksas šo datu uzglabāšanai un meklēšanas indeksa izveidošanai. Meklē-šanas pakalpojumu sniedzējam ar milzīgo datu masīvu ir jāstrādā ikdienā, šāds interneta indekss ir regulāri jāpapildina un jāaktualizē, nepārtraucot meklēšanas servisu lietotājiem. Tādēļ gan nacionāla, gan glo-bāla mēroga meklētājus nav iespējams kvalitatīvi izveidot kā sistēmas, kas darbojas tikai uz viena paša servera. Lai cik jau-dīgs nebūtu viens serveris, tradicionālajā PC serveru arhitektūrā ir limitēts gan vienam serverim pieslēdzamo disku maksimā-

lais skaits, gan operatīvās atmiņas daudzums. Pilns interneta indekss viena ser-vera atmiņā nevar brīvi ietilpst, bet tas ir obligāts priekšnoteikums servisa ātrdarbi-bai. Daudzi grēko ar kompromisa risināju-mu uz ātrdarbibas rēķina, taču tad, palielinoties lietotāju skaitam, pakalpojumu kva-litātē būtiski paslīktinās un izraisa neap-mierinātību lietotājos.

Trešā problēma ir metodika, kādā veid-dā savākt sākotnējo datu kopumu indeksa izveidošanai un pēc tam sakārtot meklēša-nas rezultātus tā, lai lietotāji būtu apmie-rināti un uzskatītu tos par pietiekami la-biem.

KĀ UZBŪVĒTS TIPIKS INTERNETA MEKLĒTĀJS

Darbības principu ilustrācijai izmanto-sim tehnoloģiju Siets, jo pēc līdzīgiem prin-cipiem ir veidota lielākā dala visu pārējo interneta meklētāju tehnoloģiju, arī, pa-saulē vadošās – Google un Yahoo.

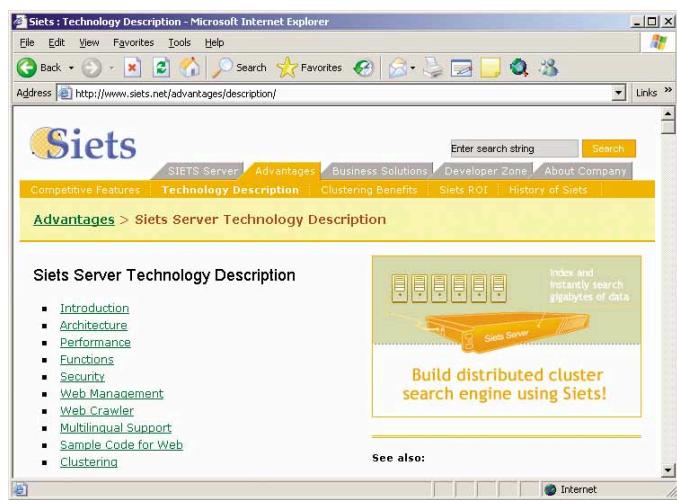
Interneta meklētājs Siets.lv izmanto-tāda paša nosaukuma meklēšanas tehnolo-giju, kurās apraksts atrodams www.siets.net (sk. 1. attēlu). Šobrīd tā ir vienīgā meklēšanas tehnoloģija Latvijā, kurās pro-grammatūru var brīvi lejupielādēt izmē-ģināšanai un izmantot dažādos – gan Inter-neta, gan korporatīvos risinājumos.

Tehnoloģijai ir divas galvenās sastāv-dalas – indeksēšanas un meklēšanas sistēma jeb tā saucamais Siets Serveris, kā arī Siets Globālais interneta rāpusis (*crawler*).

Siets Serveris ir programmatūras platforma operētājsistēmai Linux, kas darbojas kā daļītā XML datu bāze, kurās dati izvietoti uz vairākiem serveriem klastera konfigurācijā. Siets Serveri var uzglabāt jebkuras struktūras datus vairāk nekā 160 pa-sauļes valodās, tā-pēc to var uzskatīt par universālu datu uzglabāšanas un meklēšanas platfor-

mu. Siets Serveris automātiski izveido pilna teksta indeksu jebkuriem tajā ievadi-tajiem datiem. Pilna teksta indeksa izmēri ir salīdzināmi ar pašu oriģināldatu apjo-mu. Šī ir būtiskākā šādu tehnoloģiju at-šķiriba no SQL risinājumiem, kur indek-sēti tiek tikai atsevišķi datu laucini un indekss ir neliels, salīdzinot ar pašu datu apjomu.

Indeksu uzglabāšanai un meklēšanai meklētājservisa Siets.lv vajadzībām šobrīd tiek izmantoti pieci Siets klastera serveri. Tādā veidā tiek atrisināta datu uzglabā-šanas un ātrdarbibas problēma Latvijas interneta saturā indeksam. Kopējā indek-sa sastāvdajas, kas sadalītas starp serveriem, ir relatīvi nelielas, tāpēc visas indek-sēšanas un meklēšanas operācijas paralēli izmanto visu serveru operatīvo atmiņu un disku sistēmas. Palielinoties indeksējamo lapu skaitam Latvijas interneta, šādu sistēmu var mērogot ar elementāru paņēmienu – pievienojot papildu serverus šim klasterim. Arī atsevišķa servera tehniskie parametri šādā sistēmā var būt salīdzinoši pieticīgi, taupot izmaksas uz aparātu. Visbeidzot, šādā sistēmā reti kurš no lietotājiem pamana aparātūras tehniskas klūmes, jo, sabojājoties vienam no klas-tera serveriem, meklēšanas pakalpojumu serviss turpina darboties. Pēc analogiska principa – kā daudzu Linux datoru klas-tera risinājums – darbojas pasaulē po-pulārāko meklētāju Yahoo un Google vir-tuvēs tehnoloģijas.



1. attēls. Detalizēts tehnoloģijas apraksts atrodams www.siets.net.



2. attēls. SIETS.LV piedāvā arī iespēju meklēt vārdus latviešu valodas locijumos.

Otra svarīgākā sastāvdaļa tehnoloģijā Siets ir Siets interneta rāpusis. Vienkāršotā variantā šī programmatūra ir iekļauta Siets Servera komplektā, kuru lietotāji var bez maksas lejupielādēt un bez maksas izmantot, lai indeksētu līdz 20 000 dokumentiem. Šī datu savākšanas programmatūra noder, lai bez lielas programmēšanas varētu izveidot no saviem datiem tikpat ātru un spēcīgu meklēšanas funkciju, kāda jau darbojas Siets.lv interneta meklētāja. Pietiek ievadit atbilstošo Web vai intraneta serveru resursu nosaukumus, un šo serveru saturs tiks savākts, nokonvertēts uz tekstuālo informāciju un noindeksēts Siets datubāzē. Siets rāpusis atbalsta ne tikai Web lapu, bet arī Word, Excel, PDF, PowerPoint, RTF, Postscript un citu failu formātu dokumentu indeksēšanu.

Siets Globālā interneta rāpuļa programmatūra atšķiras no vienkāršotās Siets rāpuļa versijas ar to, ka automātiski seko līdzi interneta saitēm un pakāpeniski apstāgā visus kādas valsts interneta domēnus, kas atbilsts kādam norādītam augšējam domēnu limenim, piemēram, Latvijas gadījumā tas ir .LV domēns. Šādas sistēmas savāktais datu daudzums ir ļoti liels, tādēļ Siets Globālais interneta rāpusis darbojas klastera konfigurācijā.

KĀDAS IR PRIEKŠROCĪBAS LATVIJAS INTERNETA MEKLĒTĀJIEM

Daudzi lietotāji, kas līdz šim ir lietojuši Google meklētāja latviskoto versiju, šodien jau ir atklājuši, ka labākus meklēšanas rezultātus par Latvijai specifisku saturu bieži vien var iegūt, izmantojot vietējos internešu meklētājus.

Vietējiem interneta meklētājiem ir vīrķe priekšrocību, no kuriem galvenās ir lielāks vietējo datu apjoms un biežāka to indeksa aktualizācija. Gan Google, gan Yahoo grēko ar to, ka šo meklētāju rāpuli visbiežāk pārstaigā Latvijas serveru dažas galvenās lapas, taču lielāko daļu to pārējā saturā mēdz aktualizēt samērā reti – vidēji reizi mēnesī. Bieži vien pasaules meklē-

lētājos daudzās lapās sameklējamā informācija par Latvijas internetu jau ir novecojusi. Vietējās interneta meklēšanas sistēmas aktualizē datus daudz biežāk, piemēram, meklētājs Siets.lv pilnībā atjauno visu Latvijas interneta indeksu reizi nedēļā.

Vēl viena priekšrocība – vietējie meklētāji parasti indeksē 2–4 reizes vairāk lapu no Latvijas interneta saturu nekā pasaules vadotie meklētāji. Pasaules meklētāju indeksējamo lapu skaitu arī ierobežo brižiem slīktie interneta sakari ar Latvijas interneta serveriem.

Lietotāju atzinību ir ieguvusi arī dažu vietējo interneta meklētāju piedāvātā iespēja meklēt vārdus latviešu valodas locijumos, ko nepiedāvā neviens no vadotajiem pasaules meklētājiem. Latvijā raksta tapšanas brīdi šāda iespēja bija SIETS.LV (sk. 2. attēlu) un LETONIKA meklētājiem.

Daudzi diskutē par meklēšanas rezultātu kvalitāti, taču var pārliecīnāties, ka, piemēram, gan Google, gan Siets meklētājās tā ir ļoti līdzīga. Visi labākie interneta meklētāji nosaka lapu svarīgumu pēc tā, cik daudz citās interneta lapās iekļautas saites uz konkrēto lapu. Tādā veidā tiek noteikta konkrētu lapu atrašanās vieta meklēšanas rezultātos, par kuru faktiski balso visa interneta sabiedriba. Jo vairāk meklējamajam saturam atbilstošu saīšu ir citās Web lapās, kas visas norāda uz kādu konkrētu Web lapu, jo vairāk "balsu" šī lapa saņem interneta meklēšanas rezultātos. Lietotājiem zaudējot interesu par kādu resursu, atsauksmu skaits samazinās un lapas reitings arī ar laiku sarūk. Šādā veidā interneta notiek sava veida pašregulācija, kas garantē pietiekami augstu meklēšanas rezultātu kvalitāti un aktualitāti lietotāju acīs.

KĀDUS PIELIETOJUMUS VAR VEIDOT AR INTERNETA MEKLĒTĀJU TEHNOLOGIJĀM

Izmantojot to pašu tehnoloģisko risinājumu, kas noder interneta meklētāju izveidei, iespējams realizēt visdažādakos tā saucamos vertikālos meklētājus par konkrētu industriju, interešu sfēru vai objektu grupu. Tādā veidā realizēts, piemēram, Google attēlu meklētājs, vai Siets.lv Latvijas meklētājservisā – meklēšana vairāk nekā 20 citos resursos tādos kā Uzņēmumi,

Laikraksti, Personas, Spriedumi, Likumi, Nozares, Dainas, Katalogs u.c.

Tā kā visa publicētā informācija interneta faktiski satur hipersaites jeb tekstuālas norādes, ar šo tehnoloģiju ir iespējams savākt un apkopot datus pilnteksta meklēšanai par jebkura formāta informāciju – attēliem, mūzikai, biroja dokumentiem, e-pasta ziņojumiem, Web portālu komentāriem u.tml. Ar ipašu datu bāzu pieslēguma utilitu iespējams apkopot arī datus pilnteksta meklēšanai no uzņēmumu SQL datu bāzēm.

Ja ir interese veidot meklētājus par atsevišķu sfēru interneta, tad iespējams, izmantojot dažādus katalogu servisus, indeksēt tikai konkrētas sfēras uzņēmumu vai organizāciju Web resursus un izvēidot šādā veidā labus meklētājus par tūrismu, grāmatām, sportu u.tml.

Interesanti ir tas, ka šobrid visstraujāko izaugsmi pasaulei prognozē tieši vertikālu interneta meklētāju tirgum. Iemesls ir vienkāršs – vispārīgajos interneta meklētājos pasaulei (tādos kā Google) ir indeksēts tikai nepilns 1% no globālā tīmekļa saturā (daži avoti nosauc skaitli 2%, bet tas lietas būtību nemaina). Latvijas populārākie interneta meklētāji indeksē vidēji 2–4 reizes vairāk Latvijas datu nekā pasaules vadošie meklētāji, taču arī tas sastāda tikai 2–4% no Latvijas interneta publicētā saturā.

Tā kā vismaz 96% no interneta pieejamās informācijas joprojām nav ātri atradama nevienā interneta meklētājā, tad izaugsmes iespējas šajā tirgū ir acīmredzamas.

Latvijas uzņēmumiem ir iespējams ar dažādiem inovatīviem risinājumiem apsteigt pasaules līderus. Piemēram, Siets Servera programmatūras platformā ir iebūvēta iespēja veidot dažādus vietējo resursu meklētājus, izmantojot geodatus, kur meklējamais saturs tiks parādīts sakārtojumā pēc tuvākās distances no konkrētas ģeogrāfiskās koordinātas – garuma un platumā. Piemēram, Siets tehnoloģija ir piegādāta ASV biznesa direktoriņu interneta servisam MyPages (www.mypages.com/home.html), kas ar tās palīdzību katru dienu apstrādā vairāk nekā 700 000 meklēšanas pieprasījumus par 18 miljoniem ASV uzņēmumu adresu. Līdzīgas meklēšanas sistēmas, kas "jūt lietotāja atrašanās vietu", iespējams veidot dažādiem GPS un mobilajiem lietojumiem.

Gints Ernestsons,

Lursoft tehniskais direktors,

gints@lursoft.lv