

ArXiv.org e-print archive

Vypracoval: Ondřej Klobušník, sem. 3, Mgr.Ap.Inf

Datum zpracování: 6.12 2004

ArXiv.org (<http://www.arxiv.org>), dříve také znám jako LANL preprint archív, je archív pro elektronické preprinty vědeckých publikací v oborech jako je fyzika, matematika, informatika a biologie. Původně byl provozován národní laboratoří Los Alamos, nyní Cornell univerzitou a tento archív je dále zrcadlen po celém světě. ArXiv.org byl původně vyvinut panem Paulem Ginspargem. Projekt ArXiv.org započal v roce 1991 jako archív preprintů v oblasti fyziky a později byl rozšířen o matematiku, informatiku a nejnověji o biologii. V březnu roku 2004 obsahoval ArXiv.org okolo 267 000 preprintů a měsíčně přibude okolo 3 000 - 4 000 nových přírůstků. ArXiv.org byl dříve znám pod adresou xxx.lanl.gov ale název musel být změněn, bylo zjištěno že různé "censorware" programy blokovaly přístup k stránkám obsahující v názvu řetězec "xxx" pod domněnkou, že jde o pornograficky zaměřený obsah. Existence projektu ArXiv.org byla jedním z hnacích faktorů, které vedly k dnešní revoluci ve vědeckém publikování, známé jako "Open Access movement" (volně přeloženo jako hnutí pro otevřený přístup k dokumentům) s možností úplného vymizení tradičních vědeckých žurnálů. Populárním se stal "David's Front" hostovaný kalifornskou univerzitou, jde o specializovaný přehledný přístup k matematické části ArXiv.org nabízející kvalitní vyhledávání a příjemnější uživatelské rozhraní. Světově uznávané špičky v oblasti matematiky, jako např. Grigori Perelman a Richard Arenstorf, pravidelně uploadují své práce na ArXiv pro celosvětový přístup. ArXiv.org je mezinárodně zrcadlen na aps.arxiv.org (zrcadlo U.S.), lanl.arxiv.org (zrcadlo U.S.), a na dalších patnácti světových serverech. Popis systému arXiv.org Jak již bylo zmíněno, arXiv.org je archívem vědeckých publikací, speciálně návrhů které ještě nebyly veřejně publikovány (schváleny). Proces uvedení vědecké práce na veřejnost je poměrně zdlouhavý (trvá pár měsíců a někdy překročí dobu jednoho roku) a preprinty jsou vhodné medium pro komunikaci mezi vědeckou komunitou. Některé jsou výtečnými vědeckými pracemi, některé jsou průměrné a některé mají hodnotu nulovou. Minimální zárukou kvality je však fakt, že vědecké práce jsou zamýšleny pro publikování v akademických časopisech. V kontrastu s již schválenými publikacemi, preprinty se většinou necitují, většina autorů cituje právě články vydané v akademických časopisech kvůli lepší dostupnosti těchto článků. (Ačkoliv aplikace typu arXiv.org tento trend začínají měnit) V posledních letech se často místo označení "preprint" používá název "e-print", kvůli stále častější publikaci v elektronické podobě. Tento fenomén byl původně výhradou oblasti fyziky "vysokých ener-

gií” a vedl k vytvoření arXiv.org archívu Paulem Ginspargem.

Struktura systému

Archív je rozdělen na pět základních oddílů, které se dále člení. Na nejvyšší úrovni témat jsou: fyzika, matematika, nelineární systémy, informatika a kvantitativní biologie. Protože výčet celé struktury arXivu by byl zbytečným plýtváním místa, budu se po obsahové stránce věnovat podrobněji pouze informatické části. Sekce ”Informatika” zahrnuje dokumenty z oblasti architektury, umělé inteligence, distribuovaných systémů, výpočetní složitosti, výpočetního inženýrství, kryptografie a bezpečnosti, teorie her, počítačového vidění a rozpoznávání textur, počítače a společnost, kryptografie a bezpečnosti, struktur dat a algoritmů, databází, digitálních knihoven, softwarového inženýrství, robotiky aj. Podobně jako ”David’s Front” pro matematickou část arXivu, existuje také pro informatickou sekci specializovaný portál. Jmenuje se CoRR (Computing Research Repository) a najdete ho na adrese: <http://arxiv.org/corr/home> Nabízí mimo jiné i propracovaný systém pro zasílání upozornění o nových přírůstcích.

Vyhledávání na ArXiv.org

Uživatel má možnost prohledávat buď vybranou oblast nebo celý archív. Dále může prohledávat dokumenty publikované v určitém rozmezí let (např. od roku 1996 - 2004) . Standartně se pak vyhledává podle klíčových slov zadávaných do polí ”autor”, ”název” a ”abstrakt”. Citelnou chybou vyhledávání však může být absence vyhledávání podle identifikačního čísla dokumentu. Vyhledávání v archívu je bohatě dokumentováno příklady správného použití.

Identifikace dokumentů a použité formáty

Každý dokument je identifikován zkratkou názvu sekce, ve které se nachází a číslem, které je vytvořeno ze tří složek. První čtveřice čísel značí rok a měsíc ve kterém byl preprint publikován, a následuje pořadové číslo. Výsledný záznam pak vypadá například takto: ”astro-ph/0412095”. U dokumentu je vždy k dispozici ”abstrakt”, obsahující informace o dokumentu jako je název, autor a popis preprintu. Celý text je k dispozici ve formátech postscript, pdf, dvi. V případě postscriptu má uživatel na výběr bitmapové fonty a rozlišení (300 - 600 dpi) a také Type I fonty. K dispozici je také zdrojový kód pro teX.

Rozhraní a použitelnost

Grafické rozhraní je již poněkud zastaralé, avšak po funkční stránce je plně postačující. Rozvržení stránek a absence grafických prvků umožňuje jednoduché použití v textových prohlížečích (lynx).

Vlastní zhodnocení

ArXiv.org je velice specializovaný systém určený především pro vědecké účely, proto nemůže být běžný "kolemsurfující" překvapen, že zde nenalezl informace o svém "novém mobilním telefonu". Systém je stále velice používaný o čemž svědčí návštěvnost okolo 100 000 návštěv za den. Z toho co mi trochu vadí, je nemožnost vyhledávání dokumentů podle interního identifikátoru každého dokumentu a možná až příliš spartánské grafické zpracování.

Seznam literatury a zdrojů

ArXiv.org e-print archive - <http://www.arxiv.org>

WikiPedia.org - <http://www.wikipedia.org>

Computing research repository - <http://arxiv.org/corr/home>

Metadata v DC

Atribut	Schéma	Hodnota
DC.title		ArXiv.org
DC.Creator		Klobušník Ondřej
DC.Creator.Address		xklobusn@fi.muni.cz
DC.Subject		ArXiv.org
DC.Subject		e-print
DC.Subject		archive
DC.Description		ArXiv.org e-print archive, popis systému a historický vývoj
DC.Date	ISO8601	2004-12-08
DC.Type		Text
DC.Format	IMT	
DC.Identifier		http://www.fi.muni.cz/ xklobusn/pv070/arxiv.pdf
DC.Language	ISO639-1	cs