



ΕΘΝΙΚΟ ΚΑΙ ΚΑΠΟΔΙΣΤΡΙΑΚΟ
ΠΑΝΕΠΙΣΤΗΜΙΟ ΑΘΗΝΩΝ
ΣΧΟΛΗ ΘΕΤΙΚΩΝ ΕΠΙΣΤΗΜΩΝ
ΤΜΗΜΑ ΠΛΗΡΟΦΟΡΙΚΗΣ

UNIVERSAL RESOURCE IDENTIFIERS (URI)

Ε. Χατζηευθυμιάδης & Δ. Μαρτάκος
Αθήνα 1996

UNIVERSAL RESOURCE IDENTIFIERS (URI)

© 1996, Ε. Χατζηευθυμιάδης & Δ. Μαρτάκος
ΕΘΝΙΚΟ ΚΑΙ ΚΑΠΟΔΙΣΤΡΙΑΚΟ ΠΑΝΕΠΙΣΤΗΜΙΟ ΑΘΗΝΩΝ
ΣΧΟΛΗ ΘΕΤΙΚΩΝ ΕΠΙΣΤΗΜΩΝ
ΤΜΗΜΑ ΠΛΗΡΟΦΟΡΙΚΗΣ
Πανεπιστημιόπολις, Κτήρια Πληροφορικής
157 84 Αθήνα
Ελλάδα

Ε. Χατζηευθυμιάδης
MSc στην Πληροφορική, Ερευνητής
Τμήμα Πληροφορικής
Εθνικό & Καποδιστριακό Πανεπιστήμιο Αθηνών
E_mail: shadj@di.uoa.gr

Δ. Μαρτάκος
Επίκουρος Καθηγητής
Τμήμα Πληροφορικής
Εθνικό & Καποδιστριακό Πανεπιστήμιο Αθηνών
E_mail: matrakos@di.uoa.gr

ΠΕΡΙΕΧΟΜΕΝΑ

1. Γενικά	1
2. Η ανάγκη για παγκόσμια σύνταξη	1
3. URL σύνταξη	2
4. Πλήρεις, μερικές και σχετικές διευθύνσεις URL	4
5. URL πρωτοκόλλων	5
6. Επικοινωνία με Scripts μέσω τμημάτων URL	6
7. Βιβλιογραφία	8

1. Γενικά

Ενα από τα βασικότερα συστατικά του WWW είναι το πρότυπο Universal Resource Identifiers (URI) [1]. Το πρότυπο αυτό καθορίζει την σύνταξη που χρησιμοποιείται για την κωδικοποίηση των ονομάτων και των διευθύνσεων των αντικειμένων που είναι προσπελάσιμα μέσω του δικτύου Internet. Ο ιστός (web) θεωρείται ότι περιλαμβάνει αντικείμενα για την προσπέλαση των οποίων χρησιμοποιείται ένα διαρκώς αυξανόμενο πλήθος πρωτοκόλλων. Οι οδηγίες προσπέλασης (access instructions) για συγκεκριμένο αντικείμενο, με την χρήση συγκεκριμένου πρωτοκόλλου, συνθέτουν τις συμβολοσειρές διευθύνσεων (address strings). Στο Κεφάλαιο αυτό θα παρουσιαστεί η φιλοσοφία και ο μηχανισμός ανάθεσης των διευθύνσεων αυτών.

2. Η ανάγκη για παγκόσμια σύνταξη

Στον χώρο των συστημάτων αναζήτησης και ανάκτησης εγγράφων (document search & retrieval) παρατηρείται, τα τελευταία χρόνια, θεαματική ανάπτυξη. Πολλαπλά πρωτόκολλα και συστήματα θρίσκονται ήδη σε χρήση ενώ, σύντομα, αναμένεται η εισαγωγή νέων ή θελτιώσεις των ήδη υπαρχόντων. Τα συστήματα αυτά προσπαθούν να επιτύχουν την δυνατότητα σφαιρικής αναζήτησης (global search) και ανάκτησης εγγράφων που ενδεχομένως θρίσκονται σε διαφορετικές υπολογιστικές πλατφόρμες, έχουν διαφορετικές μορφές και είναι προσπελάσιμα με διαφορετικά πρωτόκολλα. Η πληθώρα πρωτοκόλλων μπορεί να αντιμετωπιστεί με την ανάπτυξη προγραμμάτων πυλών επικοινωνίας (gateways). Η πληθώρα των μορφών μπορεί να αντιμετωπιστεί με την ανάπτυξη προγραμμάτων μετατροπής (format conversion programmes). Αναφορικά όμως με τα ονόματα και τις διευθύνσεις των αντικειμένων η εισαγωγή προγραμμάτων μετατροπής κρίνεται μη πρακτική. Ο λόγος για αυτό εντοπίζεται στο γεγονός ότι τα ονόματα και οι διευθύνσεις ανταλλάσσονται και μεταφέρονται με πολλούς τρόπους και έχουν μεγάλο χρόνο ζωής.

Ενα κοινό χαρακτηριστικό των μοντέλων δεδομένων (data models) των συστημάτων της προηγούμενης παραγράφου είναι η δυνατότητα εισαγωγής της έννοιας του αντικειμένου (object) για την αναπαράσταση των περιεχομένων τους καθώς και της χρήσης ονόματος, διεύθυνσης και ενός προσδιοριστή για αυτό. Ετσι είναι εφικτός ο ορισμός χώρων ονομάτων (name spaces) στους οποίους εντάσσονται αυτά τα αντικείμενα.

Η έννοια του παγκόσμιου συνόλου αντικειμένων (universal set of objects) και, κατ' επέκταση, του παγκοσμίου συνόλου ονομάτων και διευθύνσεων (σε όλους τους υπάρχοντες χώρους) επιτρέπει τον ομοιόμορφο χειρισμό ονομάτων που ανήκουν σε

διαφορετικούς χώρους παρά το γεγονός ότι τα αντικείμενα τα οποία αντιπροσωπεύουν έχουν διαφορετικά χαρακτηριστικά. Η δυνατότητα αυτή είναι ιδιαίτερα χρήσιμη στα πληροφοριακά συστήματα που βρίσκονται εν χρήσῃ γιατί έχουν την ανάγκη να προσπελάσουν και να συνδυάσουν αντικείμενα που βρίσκονται αποθηκευμένα σε διαφορετικά συστήματα.

Το URI πρότυπο καθορίζει ένα μηχανισμό για την ενσωμάτωση αντικειμένων σε ένα χώρο ονομάτων (*name space*). Το πρότυπο URL (Uniform Resource Locators) [2] αφορά σε URLs που βασίζονται σε υπάρχοντα πρωτόκολλα επικοινωνίας και ανταλλαγής πληροφορίας. Ετοι προδιαγράφονται URLs για:

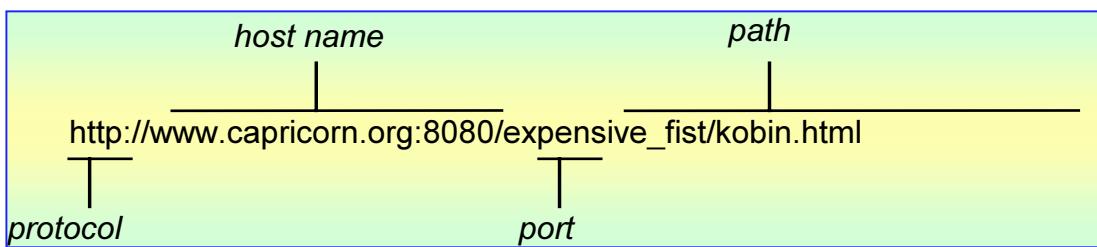
- ◆ ftp
- ◆ nntp (NEWS)
- ◆ http
- ◆ telnet
- ◆ gopher
- ◆ wais
- ◆ mailto (SMTP)
- ◆ file
- ◆ news
- ◆ prospero

Επίσης, μία προσπάθεια για τον καθορισμό χώρων μονίμων ονομάτων (*persistent name spaces*) βρίσκεται σε εξέλιξη από το Internet Engineering Task Force (IETF). Αυτά θα καλούνται URN (Uniform Resource Names), θα είναι ανεξάρτητα της θέσης του πόρου (*location independent*) και θα έχουν μεγαλύτερο χρόνο ζωής από τα URLs. Η αναζήτηση μέσω URN θα καταλήγει σε ένα URL (URN resolution to URL) του πλησιέστερου διαθέσιμου αντιγράφου του πόρου. Το URN μπορεί να αναπαριστά ένα πλήθος παραλλαγών ενός βασικού πόρου.

Οι βασικές κατευθύνσεις πάνω στις οποίες κινήθηκε ο σχεδιασμός του URI προτύπου είναι η επεκτασιμότητα (*extensible syntax*), η πληρότητα (*complete syntax*) και η δυνατότητα εκτύπωσης (*printable syntax*). Η πληρότητα αφορά στην δυνατότητα κωδικοποίησης οποιουδήποτε σχήματος απόδοσης ονομάτων (*naming scheme*). Για την κάλυψη της τελευταίας απαίτησης χρησιμοποιούνται χαρακτήρες ASCII 7 bits.

3. URL σύνταξη

Η γενική σύνταξη URL παρουσιάζεται στο σχήμα 1 το οποίο ακολουθεί. Το πρώτο τμήμα της διεύθυνσης καθορίζει το πρωτόκολλο επικοινωνίας (protocol) ή σχήμα απόδοσης ονομάτων (*naming scheme*) όπως καλείται στο πρότυπο. Ο τρόπος ερμηνείας όλου του υπολοίπου τμήματος της διεύθυνσης εξαρτάται άμεσα από το σχήμα αυτό (*schema specific part*). Διαχωριστής των δύο είναι ο χαρακτήρας ":".



Σχήμα 1: Γενική μορφή URL

Το δεύτερο τμήμα της διεύθυνσης προσδιορίζει το υπολογιστικό σύστημα (*host*) στο οποίο φιλοξενείται ο ζητούμενος πόρος. Στο ίδιο τμήμα, προαιρετικά συμπεριλαμβάνεται η θύρα (*port*) μέσω της οποίας πρόκειται να πραγματοποιηθεί η επικοινωνία. Για τα διάφορα πρωτόκολλα, που το σχήμα URL μπορεί να εξυπηρετήσει, έχουν προδιαγραφεί συγκεκριμένες θύρες επικοινωνίας (*default ports*). Ετσι, ο προσδιορισμός της θύρας στο URL είναι επιβεβλημένος όταν δεν χρησιμοποιείται η προδιαγεγραμμένη. Για την επικοινωνία WWW συνήθως χρησιμοποιείται η θύρα 80 ενώ για ανταλλαγές αρχείων μέσω FTP η 21. Ο προσδιορισμός του συστήματος μπορεί να γίνει με τις συνήθεις IP διευθύνσεις ή με ονόματα (χρήση της υπηρεσίας DNS). Το υπόλοιπο τμήμα της διεύθυνσης καλείται URL *path* και χρησιμοποιείται για να υποδείξει στο υπολογιστικό σύστημα την ακριβή θέση του αιτούμενου πόρου. Η μορφή του είναι διαφορετική για τα διάφορα πρωτόκολλα. Για παράδειγμα, σε ορισμένες περιπτώσεις μπορεί να υποδεικνύει ένα αρχείο ενώ σε άλλες μία ερώτηση που θα πρέπει να εκτελεστεί σε μία ΒΔ.

Σε μία διεύθυνση URL η χρήση ορισμένων μόνο χαρακτήρων είναι επιτρεπτή. Οι κεφαλαίοι, πεζοί χαρακτήρες και οι αριθμοί βρίσκονται μεταξύ αυτών καθώς και οι χαρακτήρες \$_@-. Οι χαρακτήρες =;#?%&+ καθώς και το space μπορούν να χρησιμοποιηθούν αλλά έχουν συγκεκριμένη σημασία στις URL διευθύνσεις. Οι χαρακτήρες αυτοί καλούνται δεσμευμένοι (reserved) χαρακτήρες. Όλοι οι υπόλοιποι χαρακτήρες δεν μπορούν να χρησιμοποιηθούν στην διαμόρφωση διευθύνσεων και θα πρέπει να γίνουν escape. Οι κωδικοί διαφυγής (escape codes) για τους χαρακτήρες αυτούς αποτελούνται από το σύμβολο % και το δεκαεξαδικό αντίστοιχο του χαρακτήρα. Ετσι το carriage return υποκαθίσταται από το %0D. Η τελευταία κατηγορία χαρακτήρων χαρακτηρίζονται μη ασφαλείς (unsafe).

Τα τμήματα των URLs που ενσωματώνονται στις αιτήσεις διαφέρουν ανάλογα με το αν αυτές υποθάλλονται στον κανονικό server ή σε proxy server.

4. Πλήρεις, μερικές και σχετικές διευθύνσεις URL

Οι Uniform Resource Locators μπορεί να είναι πλήρεις (complete), μερικοί (partial) ή σχετικοί (relative). Οι πλήρεις διευθύνσεις περιέχουν όλα τα τμήματα που παρουσιάστηκαν παραπάνω, δηλαδή τα protocol, host name και path τμήματα. Σε αντίθεση με τις πλήρεις διευθύνσεις, στις σχετικές δεν περιέχονται τα τμήματα protocol και host name. Οταν οι browsers συναντήσουν ανάλογες διευθύνσεις τις ερμηνεύουν σε σχέση με τον τρέχων πόρο το οποίο χειρίζονται (π.χ. σελίδα WWW). Τα τμήματα protocol και host name θεωρούνται τα ίδια. Ετοι, εάν κάποιος browser έχει επισκεφτεί την σελίδα:

http://www.capricorn.org/heavy_industry.html

και άμεσα συναντήσει την URL διεύθυνση:

</careers/steel.html>

Θα αναζητήσει την σελίδα:

<http://www.capricorn.org/careers/steel.html>

Με βάση τα παραπάνω μπορούν να οριστούν οι σχετικές URL διευθύνσεις. Στην περίπτωση των σχετικών διευθύνσεων όλα τα τμήματα που προδιαγράφονται στο URL πρότυπο συμπεριλαμβανόμενο και του url-path ερμηνεύονται σε σχέση με τον τρέχων πόρο. Ετοι δεν απαιτείται ο προσδιορισμός των host name, protocol αλλά και τμήματος του path που οδηγεί στο ζητούμενο πόρο. Εάν, για παράδειγμα ο browser, αφού επισκεπτεί την σελίδα

http://www.capricorn.org/heavy_industry.html

συναντήσει την URL διεύθυνση:

<steel.html>

Θα αναζητήσει την σελίδα:

<http://www.capricorn.org/steel.html>

Στον μηχανισμό αυτό, των σχετικών διευθύνσεων πόρων μπορούν να εφαρμοστούν οι προσδιοριστές . και .. για το current και το parent directory αντίστοιχα (relative paths). Η χρήση σχετικών URL προϋποθέτει μία ιεραρχική δόμηση των εμπλεκόμενων πόρων π.χ. ένα σύστημα αρχείων.

Οι σχετικές διευθύνσεις URL κρίνονται ιδιαίτερα χρήσιμες για την κατασκευή λογικά συνδεδεμένων συνόλων εγγράφων (documents) στο πλαίσιο ενός site. Πιθανές μετακινήσεις των εγγράφων από σύστημα σε σύστημα μέσα στο site ή ακόμη και σε διαφορετικό site επηρεάζουν ελάχιστα την παραπάνω δομή εξαιτίας της χρήσης σχετικών URL.

5. URL πρωτοκόλλων

Οπως αναφέρθηκε στην παράγραφο 2 από τα URIs προκύπτουν URLs για ένα σύνολο από ευρέως διαδεδομένα και χρησιμοποιούμενα πρωτόκολλα. Ετσι υπάρχουν συγκεκριμένα URLs για FTP, SMTP, NNTP κ.α. Σε αυτή την παράγραφο θα παρουσιαστούν τα HTTP URLs τα οποία σχετίζονται άμεσα με το αντικείμενο της εργασίας. Τα URLs αυτά μπορούν να περιγράψουν (υποδείξουν) τα εξής [3]:

- ⤒ *Eva αρχείο σε έναν HTTP server.*
- ⤒ *Την λίστα καταλόγου (directory listing) σε ένα HTTP server.*
- ⤒ *Eva εκτελέσιμο αρχείο (script) σε ένα HTTP server.*
- ⤒ *Eva εκτελέσιμο αρχείο χωρίς παραμέτρους.*
- ⤒ *Eva αρχείο, σε κατάλογο χρήστη, το οποίο διατίθεται μέσω του HTTP server.*
- ⤒ *Eva εκτελέσιμο αρχείο, σε κατάλογο χρήστη, του οποίου το αποτέλεσμα εκτέλεσης διατίθεται μέσω του HTTP server.*

Μία HTTP URL έχει την γενική μορφή:

http://<host>:<port>/<path>?<searchpart>

Τα τμήματα <host> και <port> ερμηνεύονται σύμφωνα με τα λεγόμενα στην παράγραφο 3. Εάν το τμήμα <port> παραληφθεί ως τιμή του θεωρείται η 80. Δεν επιτρέπεται η χρήση username και password όπως αυτά προδιαγράφονται στην Common Internet Scheme Syntax [2]. Τα username και password χρησιμοποιούνται σε URLs άλλων πρωτοκόλλων όπως π.χ. FTP και TELNET. Η χρήση των <path> και <searchpart> είναι προαιρετική. Το <searchpart> περιέχει την συμβολοσειρά ερώτησης (query string). Το <path> υποδιεκνύει την ακριβή θέση του αιτούμενου πόρου (resource path). Στα δύο τελευταία τμήματα του URL οι χαρακτήρες /; και ? είναι δεσμευμένοι.

Η θέση του πόρου (resource path) προσδιορίζεται όπως ακριβώς τα αρχεία στο σύστημα UNIX. Αν και υπάρχει όμως αυτή η ομοιότητα, το συγκεκριμένο τμήμα του URL δεν αντιστοιχεί στο ακριβές path του πόρου. Μόλις η σχετική αίτηση φτάσει στον HTTP server αυτός ερμηνεύει το resource path σε σχέση με το προκαθορισμένο document root directory (root directory του WWW server). Για τον λόγο αυτό το τμήμα <path> συχνά καλείται virtual path.

Ο browser μπορεί να ζητήσει συγκεκριμένο τμήμα ενός εγγράφου (πόρου) κάνοντας χρήση του fragment identifier "#". Ενδεικτικά αναφέρεται το URL:

http://www.myu.edu/org/admin/people#andy

Ο server, στην περίπτωση αυτή θα επιστρέψει το ζητούμενο αρχείο. Η συμβολοσειρά #andy δεν συμπεριλαμβάνεται στην σχετική αίτηση. Χρησιμοποιείται μετά την

ανάκτηση του εγγράφου για τον προσδιορισμό του τμήματος (fragment) που φέρει τον τίτλο andy. Η έννοια του fragment προσδιοριστή προέρχεται από το πρότυπο URI και δεν αφορά μόνο τα HTTP URLs. Καλύπτει περιπτώσεις υποτμημάτων ή υπολειτουργιών κάποιου αντικειμένου.

Οι HTTP servers αντιδρούν με διάφορους τρόπους στις υποθαλλόμενες αιτήσεις ανάλογα με το είδος του πόρου το οποίο αφορούν. Εάν η αίτηση υποδεικνύει κάποιο αρχείο o server θα επιστρέψει στον client το περιεχόμενο του. Ο τρόπος χειρισμού του από τον client δεν τον αφορά καθόλου. Εάν το <path> υποδεικνύει κάποιον κατάλογο (directory) o server μπορεί να:

1. επιστρέψει μία συγκεκριμένη HTML σελίδα (αρχείο) που περιέχεται στον κατάλογο αυτό. Συχνά οι σελίδες αυτές φέρουν τα ονόματα welcome.html ή index.html και καλούνται welcome pages.
2. Εάν δεν υπάρχει το αρχείο της περιπτώσεως 1 o server κατασκευάζει και επιστρέφει στον client μία λίστα καταλόγου (directory listing) για τον κατάλογο τον οποίο υπέδειξε.

Τα HTTP URLs μπορούν να υποδεικνύουν εκτελέσιμα αρχεία. Οταν o server δεχτεί μία ανάλογη αίτηση καλεί το προσδιοριζόμενο πρόγραμμα και επιστρέφει τα αποτελέσματα εκτέλεσης του στον client. Το πέρασμα πληροφορίας από το URL προς το εκτελέσιμο αρχείο γίνεται μέσω του <searchpart> (query string) το οποίο χωρίζεται από το υπόλοιπο URL με τον χαρακτήρα "?". Το πέρασμα πληροφορίας σε εκτελέσιμα αρχεία μέσω των URLs αποτελεί αντικείμενο της ακόλουθης παραγράφου.

6. Επικοινωνία με Scripts μέσω τμημάτων URL

Το περιεχόμενο του συγκεκριμένου κεφαλαίου είναι στενά συνδεδεμένο με το Common Gateway Interface (CGI). Αφορά στις περιπτώσεις στις οποίες για την εκτέλεση ενός script από τον server απαιτείται πληροφορία από τον client η οποία ενσωματώνεται σε URLs. Οπως αναφέρθηκε παραπάνω ότι ακολουθεί τον χαρακτήρα "?" είναι γενικότερα γνωστό ως query string. Για παράδειγμα ο hypertext σύνδεσμος:

Click here

προκαλεί την εκτέλεση του script lookup με παράμετρο την συμβολοσειρά "The Raven". Οπως είναι προφανές και το query string ακολουθεί την κωδικοποίηση URL και χρησιμοποιεί κωδικούς διαφυγής για ορισμένους χαρακτήρες.

Τα query strings γενικά ταξινομούνται σύμφωνα με την μορφή τους σε δύο βασικές κατηγορίες. Η πρώτη αναφέρεται ως keyword list (λίστα λέξεων κλειδιών) και χρησιμοποιείται κατά κύριο λόγο σε scripts τα οποία πραγματοποιούν αναζήτηση

κειμένου (word search). Τα περιεχόμενα του query string χωρίζονται μεταξύ τους με τον χαρακτήρα "+". Ενα παράδειγμα URL αυτής της κατηγορίας δίνεται στην συνέχεια:

Click here

Από το παράδειγμα είναι προφανές ότι οι χαρακτήρες "+" που ενδεχομένως περιέχονται στην πληροφορία που περνάει στο script θα πρέπει να κωδικοποιούνται.

Η δεύτερη κατηγορία αναφέρεται ως named parameters list και χρησιμοποιείται από scripts τα οποία προσπελαύνουν περισσότερο σύνθετες δομές δεδομένων. Μία named parameters list έχει την μορφή:

name1=value1&name2=value2&name3=value3&.....

Το query string αποτελείται από ένα σύνολο ζευγών name, value τα οποία ξεχωρίζουν μεταξύ τους με το σύμβολο "&". Το κάθε ζεύγος θεωρείται ότι αντιπροσωπεύει μία named parameter (μία παράμετρο για την οποία υπάρχει συγκεκριμένο όνομα). Ενα παράδειγμα για την μορφή αυτή των URL δίνεται στην συνέχεια:

Click here

Το παράδειγμα αφορά το πέρασμα δύο παραμέτρων στο script lookup. Η πρώτη από τις παραμέτρους αυτές φέρει το όνομα author ενώ η δεύτερη title. Οι τιμές των παραμέτρων στο URL είναι "Poe" και "The Raven" αντίστοιχα.

Σε ορισμένες περιπτώσεις πρόσθετη πληροφορία (πλέον του query string) περνάει στα scripts με την μορφή path information. Η πληροφορία αυτή ενσωματώνεται στο URL μετά από το path και το filename του εκτελέσιμου αρχείου. Λόγω του ενιαίου τρόπου σύνταξης (ο οποίος επιδεικνύεται και στο ακόλουθο παράδειγμα) υπάρχει το πρόβλημα διάκρισης του script από το path information. Ο server σταματάει να διαβάζει το URL μόλις εντοπίσει το όνομα ενός εκτελέσιμου αρχείου. Η υπόλοιπη πληροφορία περνάει στο script σαν path information (PATH_INFO στο πρωτόκολλο CGI) και ο τρόπος ερμηνείας της είναι αποκλειστική ευθύνη του script. Εάν το URL περιέχει query string αυτό προστίθεται στο τέλος της όλης συμβολοσειράς. Την περίπτωση αυτή καλύπτει το ακόλουθο παράδειγμα hypertext link.

Click Here

Στο παράδειγμα, το script είναι το puzzle στο οποίο περνά σαν path information η πληροφορία /ducks/and/drake. Επίσης στο ίδιο script, σαν παράμετροι περνούν, μέσω του query string, οι row και cl.

Θα πρέπει να επισημανθεί ότι στην περίπτωση που ορίζεται query string το σχετικό URL (URI) αναπαριστά το αποτέλεσμα εφαρμογής της αιτούμενης λειτουργίας (π.χ. ερώτηση) στο αρχικά προσδιοριζόμενο αντικείμενο.

7. Βιβλιογραφία

- [1] Berners-Lee T.: *Universal Resource Identifiers in WWW: A Unifying Syntax for the Expression of Names and Addresses of Objects on the Network as used in the World Wide Web*, RFC 1630, CERN (June 1994).
- [2] Berners-Lee T., Masinter L. and McCahill M. Editors: *Uniform Resource Locators (URL)*, RFC 1738, CERN, Xerox Corporation, University of Minnesota (December 1994).
- [3] Stein Lincoln: *How to Set Up and Maintain a World Wide Web Site*, Addison-Wesley (1995).