



Πτυχιακή Εργασία

Ανάπτυξη Σελίδας Στασιστικών Για Τον Web Server Του Τμήματος

Βαβάλας Απόστολος

Ιούνιος 2009

Α.Τ.Ε.Ι. ΘΕΣΣΑΛΟΝΙΚΗΣ
ΣΧΟΛΗ ΤΕΧΝΟΛΟΓΙΚΩΝ ΕΦΑΡΜΟΓΩΝ
ΤΜΗΜΑ ΠΛΗΡΟΦΟΡΙΚΗΣ

A.T.E.I.Th.
Τμήμα Πληροφορικής

Θέμα Πτυχιακής Εργασίας :

Ανάπτυξη Σελίδας Στατιστικών για τον Web
Server του Τμήματος

Βαβάλας Απόστολος 03/2383
apvav@it.teithe.gr

Περιεχόμενα

1 ΠΡΟΛΟΓΟΣ	7
2 ΕΙΣΑΓΩΓΗ	9
2.1 ΣΚΟΠΟΣ	9
2.2 ΑΠΑΙΤΗΣΕΙΣ	9
2.3 SERVER AETOS	10
2.3.1 Εγκατεστημένα Πακέτα	12
2.4 ΕΡΓΑΛΕΙΑ ΠΟΥ ΧΡΗΣΙΜΟΠΟΙΗΘΗΚΑΝ	12
2.4.1 Python	12
2.4.2 PHP	13
2.4.2.1 GD2	13
2.4.3 Smarty Template Engine	14
2.4.4 Graphpите	15
2.4.5 CSS	17
3 ΥΠΑΡΧΟΝΤΑ ΕΡΓΑΛΕΙΑ	19
3.1 AWSTATS	19
3.2 ANALOG	20
3.3 WEBALIZER	20
3.4 ΜΕΤΡΗΤΕΣ (COUNTERS)	21
4 ΔΟΜΗ / ΑΝΑΛΥΣΗ	23
4.1 ΓΛΩΣΣΕΣ ΥΛΟΠΟΙΗΣΗΣ	23
4.1.1 Parser	23
4.1.2 Βάση Δεδομένων	24
4.1.3 Web Interface	24
4.2 ΣΧΗΜΑ ΒΑΣΗΣ	24
4.2.1 Πίνακες Βάσης	26
4.2.2 SQL κώδικας δημιουργίας των tables	28
4.2.3 Σχεδιάγραμμα ER της Βάσης	31
5 ΑΝΑΛΥΣΗ ΚΩΔΙΚΑ	33
5.1 LAUNCHER.SH	33
5.1.1 Κώδικας του launcher.sh	33

5.2 PARSER.PY	33
5.3 WEB INTERFACE	39
5.3.1 Προγραμματιστικό μέρος web interface	40
5.3.2 Γραφήματα του graphs.php	43
5.3.3 Counter	47
6 ΕΓΚΑΤΑΣΤΑΣΗ	51
6.1 ΑΠΑΙΤΗΣΕΙΣ ΣΥΣΤΗΜΑΤΟΣ	51
6.2 ΟΔΗΓΙΕΣ ΕΓΚΑΤΑΣΤΑΣΗΣ	51
6.2.1 Εγκατάσταση counter σε ιστοσελίδα	53
7 ΧΡΗΣΗ	55
7.1 SHELL ΕΝΤΟΛΕΣ	55
7.2 ΟΔΗΓΙΕΣ ΧΡΗΣΗΣ	56
8 ΣΧΟΛΙΑ / ΠΑΡΑΤΗΡΗΣΕΙΣ	63
9 ΕΠΙΛΟΓΟΣ	65

1 ΠΡΟΛΟΓΟΣ

Η πτυχιακή εργασία που αναπτύσσεται σε αυτό το κείμενο έχει θέμα “Ανάπτυξη Σελίδας Σταστιστικών για τον Web Server του τμήματος”. Πρόκειται για την υλοποίηση ενός εργαλείου που συλλέγει στοιχεία για τις επισκέψεις στον server aetos από τα access logs της HTTP υπηρεσίας και τα παρουσιάζει μέσω ενός web interface. Οι απαιτούμενες γνώσεις για αυτήν την εργασία προέρχονται από διάφορους κλάδους της επιστήμης της πληροφορικής όπως ο προγραμματισμός, οι βάσεις δεδομένων και τα λειτουργικά συστήματα.

Στο κεφάλαιο Εισαγωγή αναφέρονται τα χαρακτηριστικά του web server του τμήματος και παρουσιάζονται τα εργαλεία που χρησιμοποιήθηκαν για την υλοποίηση της εφαρμογής. Στο επόμενο κεφάλαιο γίνεται αναφορά σε υπάρχοντα εργαλεία που αναλογούν web logs, στα χαρακτηριστικά τους και παρουσιάζονται οι διαφορές τους. Το κεφάλαιο τέσσερα είναι αφιερωμένο στην παρουσιάση της δομής της υπηρεσίας καθώς και στους λόγους επιλογής των εργαλείων υλοποίησης για κάθε επιμέρους δομικό στοιχείο της. Στη συνέχεια αναλύεται ο κώδικας της εφαρμογής και ο τρόπος λειτουργίας του. Το έκτο κεφάλαιο αναφέρεται στις απαιτήσεις τους συστήματος και δίνονται οδηγίες για την εγκατάσταση του εργαλείου. Τέλος δίνονται αναλυτικές οδηγίες χρήσης, παρουσιάζονται στοιχεία από τη λειτουργεία της εφαρμογής στο server του τμήματος καθώς και φωτογραφίες από την ιστοσελίδα της υπηρεσίας.

Η web based εφαρμογή αναπτύχθηκε σε περιβάλλον Unix χρησιμοποιώντας ελεύθερο λογισμικό και ονομάστηκε webstats. Η ηλεκτρονική διεύθυνση της ιστοσελίδας της υπηρεσίας είναι :

- <http://www.it.teithe.gr/~aprvan/webstats>

2 ΕΙΣΑΓΩΓΗ

2.1 ΣΚΟΠΟΣ

Ο σκοπός της εφαρμογής είναι η ύπαρξη ενός εργαλείου που παρουσιάζει στατιστικά μεγέθη σχετικά με τις επισκέψεις στους ιστότοπους των λογαριασμών του server του τμήματος. Το εργαλείο είναι χτισμένο επάνω στις απαιτήσεις και στις ιδιαιτερότητες του aetos, η σημαντικότερη από αυτές είναι ότι φιλοξενεί πολλούς ιστότοπους λόγω των πολλών λογαριασμών. Περισσότερα σχετικά με τον server του τμήματος παρουσιάζονται στην υποενότητα 2.3.

Σκοπός της εφαρμογής δεν αποτελεί μόνο η εμφάνιση στοιχείων για τις επισκέψεις στην κάθε ιστοσελίδα αλλά και η ενημέρωση στο τι είδους ιστότοποι παρουσιάζουν το μεγαλύτερο ενδιαφέρον. Για αυτόν το λόγο οι χρήστες του aetos κατηγοριοποιήθηκαν ως προς την ιδιότητα τους στο τμήμα, δηλαδή σε προσωπικό και φοιτητές, έτσι δώθηκε η δυνατότητα υπολογισμού στατιστικών ειδικά για αυτές τις κατηγορίες. Ενδιαφέρον θεωρήθηκε και ο υπολογισμός διαφόρων άλλων στοιχείων όπως οι χρήστες και τα χρονικά διαστήματα με τις περισσότερες επισκέψεις.

2.2 ΑΠΑΙΤΗΣΕΙΣ

Οι απαιτήσεις μας από αυτό το εργαλείο δεν είναι άλλες από την ενημέρωση μας για την web κίνηση στο server με στατιστικά μεγέθη και σχεδιαγράμματα για την ασφαλή εξαγωγή συμπερασμάτων σχετικά με αυτή. Σημαντικό είναι τα στοιχεία να εμφανίζονται και για κάθε χρήστη του server ξεχωριστά. Τα στοιχεία αυτά είναι ο αριθμός των επισκέψεων και ο όγκος των δεδομένων που έχουν μεταφερθεί. Μία ακόμα απαίτηση είναι η παρουσίαση αυτών των μεγεθών, όχι μόνο ως προς το σύνολο τους αλλά και για ξεχωριστά χρονικά διαστήματα.

Αυτά τα διαστήματα είναι :

- Η τρέχουσα ώρα
- Η τρέχουσα ημέρα
- Ο τρέχων μήνας
- Οι τελευταίοι τρεις μήνες
- Οι τελευταίοι έξι μήνες
- Το τρέχων έτος

- Τα τελευταία δύο έτη
- Συνολικά

Όπως αναφέρθηκε παραπάνω οι λογαριασμοί απαιτείται να χωρίζονται σε κατηγορίες προσωπικού και φοιτητών. Πέραν αυτών δημιουργήθηκε μία ακόμα κατηγορία για την καλυψη μελλοντικών αναγκών με όνομα other. Αυτή η απαίτηση οφειλόταν στο να υπάρχει η δυνατότητα υπολογισμού της κατανομής των επισκέψεων ανά κατηγορία και των ποσοστών τους επί τοις εκατό.

Ένας επιπλέον λόγος αυτής της ομαδοποίησης είναι η ενημέρωση για την web κίνηση σε μία μεγαλύτερη κλίμακα και την παρουσίαση στοιχείων αρθροιστικά για τις ιστοσελίδες του προσωπικού και των φοιτητών. Έτσι μας δίνεται η δυνατότητα να γνωρίζουμε πως μοιράζεται η κίνηση στον server και ποια είναι η κατανομή των επισκέψεων ανάμεσα στην κεντρική σελίδα του τμήματος, δηλαδή τις ιστοσελίδες στο root directory του apache, τους ιστότοπους του προσωπικού και των φοιτητών.

Ακόμη μία απαίτηση από αυτήν την υπηρεσία είναι η ενημέρωση στατιστικών μεγεθών όπως μέσοι όροι αλλά και η αναλυτική παρουσίαση των επισκέψεων για χρονικά διαστήματα όπως οι τελευταίες ώρες, μέρες, μήνες και έτη. Οι κατανομές που υπολογίζονται είναι η κατανομή ανά κατηγορία όπου αναφερθήκαμε στην προηγούμενη παράγραφο και η κατανομή ανά ώρα, δηλαδή πως κατανέμεται η επισκεψιμότητα κατά τη διάρκεια μιας ημέρας. Το να γνωρίζουμε το ποιες ώρες γίνονται οι περισσότερες επισκέψεις και ποίες όχι είναι ένα πολύ ενδιαφέρον στατιστικό στοιχείο.

Για την εμφάνιση μεγεθών όπως οι κατανομές στις οποίες αναφερθήκαμε αλλά και η αναπαράσταση της κίνησης για ένα χρονικό διάστημα θεωρήθηκε πως η χρήση γραφημάτων θα ήταν ιδιαίτερα χρήσιμη για τη κατανόηση τους. Σχεδιαγράμματα παρουσιάζουν τη διακύμανση της επισκεψιμότητας για τα χρονικά διαστήματα των τελευταίων ωρών, ημερών, μηνών και ετών. Επίσης και για τους μήνες του κάθε έτους ξεχωριστά.

2.3 SERVER AETOS

Όπως προαναφέρθηκε το εργαλείο webstats δημιουργήθηκε ειδικά για τον aetos, τον server του τμήματος. Αυτό σημαίνει πως χτίστηκε σύμφωνα με τα χαρακτηριστικά και τις ρυθμίσεις του aetos, για αυτό θεωρήθηκε σκόπιμο να γίνει ειδική αναφορά σε αυτόν και τα χαρακτηριστικά του.

Βασικά χαρακτηριστικά του server του τμήματος :

- Το λειτουργικό σύστημα είναι Debian GNU/Linux 5.0
- Ο http υπηρεσία που τρέχει είναι ο Apache 2.2.9
- Ο web server έχει ενεργοποιημένη την usredir επιλογή, έτσι ο κάθε χρήστης μπορεί να ανεβάσει ιστοσελίδα. Η εντολή για την ενεργοποίηση αυτής της ρύθμισης είναι :

```
a2enmod userdir
```

- Ο web server ακούει σε δύο domain names. Αυτά είναι :
 1. http://www.it.teithe.gr
 2. http://aetos.it.teithe.gr
- Η ηλεκτρονική διεύθυνση των ιστοσελίδων των χρηστών είναι το url του aetos ακολουθούμενο από τον χαρακτήρα ~ και το όνομα του λογαριασμού. Παραδείγματος χάριν για τον χρήστη αρναν :
 1. http://www.it.teithe.gr/~apnav ή
 2. http://aetos.it.teithe.gr/~apnav
- Ένα ακόμα feature που είναι ενεργοποιημένο στον Apache στον aetos είναι το suEXEC. Αυτή η λειτουργία επιτρέπει στους χρήστες του web server να τρέχουν CGI προγράμματα κάτω από διαφορετικό ID από αυτό της web υπηρεσίας, έτσι μειώνεται το ρίσκο σε θέματα ασφάλειας.
- Τα access logs του Apache αποθηκεύονται στα παρακάτω δύο αρχεία, ένα για κάθε domain name.
 1. /var/log/apache2/aetos-access.log
 2. /var/log/apache2/www-access.log
- Όσον αφορά τα access logs θα πρέπει να αναφερθεί το format τους πάνω στο οποίο υλοποιήθηκε το parsing. Το format με το οποίο αποθηκεύονται τα logs στον aetos είναι το combined. Το webstats υποστηρίζει επιπλέον το common format μόνο που σε αυτήν την περίπτωση δε λειτουργεί το φιλτράρισμα στα logs που προέρχονται από robots και spiders. Η combined μορφή είναι η common με την προσθήκη δύο ακόμα πεδίων, του referer και του user-agent. Η μορφή των δύο αυτών format είναι :
 1. LogFormat "%h %l %u %t \"%r\" %>s %b" common

Παράδειγμα :

 - 127.0.0.1 - frank [10/Oct/2000:13:55:36 -0700] "GET /apache_pb.gif HTTP/1.0"
200 2326
 2. LogFormat "%h %l %u %t \"%r\" %>s %b \"%{Referer}i\" \"%{User-agent}i\""
combined

Παράδειγμα :

 - 127.0.0.1 - frank [10/Oct/2000:13:55:36 -0700] "GET /apache_pb.gif HTTP/1.0"
200 2326 "http://www.example.com/start.html" "Mozilla/4.08 [en] (Win98; I
;Nav)"

- Το webstats συνδέεται στην PostgreSQL τοπικά. Για να επιτραπεί μια δικτυακή σύνδεση στην PostgreSQL στον aetos όταν πρέπει να γίνει από IP διεύθυνση που ανήκει στο δίκτυο του Τ.Ε.Ι. Θεσσαλονίκης.

2.3.1 Εγκατεστημένα Πακέτα

Παρακάτω ακολουθεί η λίστα των εγκατεστημένων πακέτων στον aetos που χρησιμοποιούνται από το webstats.

- python
- postgresql
- python-pgsql
- php5-pgsql
- php5
- php5-gd
- smarty
- logtail

Για την εγκατάστηση των παραπάνω πακέτων στα Debian απαιτείται η εντολή :

```
apt-get install package-name
```

2.4 ΕΡΓΑΛΕΙΑ ΠΟΥ ΧΡΗΣΙΜΟΠΟΙΗΘΗΚΑΝ

2.4.1 Python

Η python είναι μία high-level γλώσσα προγραμματισμού και αναπτύσσεται ώς ανοιχτό λογισμικό. Έχει δωθεί ιδιαίτερη έμφαση στο συντακτικό της ώστε να είναι ευανάγνωστο και απλό. Υποστηρίζει πολλά προγραμματιστικά στύλ και εκτελείται με την κλήση interpreter. Συχνά χρησιμοποιείται ως scripting language σε web applications. Βρίσκεται σε όλες τις Linux διανομές, NetBSD και OpenBSD ως βασικό component.

- Ακολουθεί ένα παράδειγμα κώδικα που δείχνει πόσο λιτό είναι το συντακτικό της python :

```

1  #!/usr/bin/python
2
3  def function1(a,b):
4      x = a + b;
5      return x;
6
7  print "Python Example";
8  x = function1(4,3);
9  print x;

```

2.4.2 PHP

Η PHP είναι μία scripting language που δημιουργήθηκε για να παράγει ιστοσελίδες με δυναμικό περιεχόμενο, στην συνέχεια εξελίχτηκε σαν μια γλώσσα γενικότερων σκοπών. Χρησιμοποιείται κυρίως για side server programming και web applications καθώς μπορεί να ενσωματώσει HTML κώδικα. Είναι ελεύθερο λογισμικό και διατίθεται σχεδόν για όλα τα λειτουργικά συστήματα.

- Παράδειγμα :

```

<HTML>
  <HEAD>
    <TITLE> PHP </TITLE>
  </HEAD>
  <BODY>
    <?php echo "<p>Dynamic output.</p>"; ?>
    <p>Static output.</p>
  </BODY>
</HTML>

```

2.4.2.1 GD2

Μία από της standard βιβλιοθήκες της PHP είναι και η GD 2 που είναι εγκατεστημένη στον aetos. Αυτή η βιβλιοθήκη δίνει την δυνατότητα δημιουργίας εικόνων δυναμικά. Μπορεί να παράγει αρχεία όπως gif, jpg και png.

- Παράδειγμα :

```

<?php
// Create a 150*20 image
$im = imagecreate(150, 20);
// blue background and white text

```

```

$bg = imagecolorallocate($im, 255, 255, 255);
$textcolor = imagecolorallocate($im, 0, 0, 255);
imagestring($im, 5, 0, 0, 'Created by PHP', $textcolor);
// Output the image
header('Content-type:image/png');
imagepng($im);
imagedestroy($im);
?>

```

Το παραπάνω παράδειγμα θα δημιουργήσει αυτήν την εικόνα :



Figure 2.1: Παράδειγμα GD

2.4.3 Smarty Template Engine

To Smarty είναι ένα Web Template σύστημα. Είναι γραμμένο σε PHP και δημιουργήθηκε για να διαχωρίζει το προγραμματιστικό μέρος από αυτό της εμφάνισης. Με αυτόν τον τρόπο αποφεύγεται ο συνδυασμός ρφρ κώδικα με html tags.

Τυποποιεύεται δομές ελέγχου και επανάληψης, δήλωση μεταβλητών, δημιουργία συναρτήσεων και δίνει την δυνατότητα σε υψηλού επιπέδου template programming.

- Παράδειγμα PHP κώδικα που χρησιμοποιεί το Smarty :

```

<?php
    //put full path to Smarty.class.php
    require('/usr/share/php/smarty/libs/Smarty.class.php');
    $smarty = new Smarty();
    $smarty->template_dir = "/var/www/smarty/templates";
    $smarty->compile_dir = "/var/www/smarty/templates_c";
    $smarty->cache_dir = "/var/www/smarty/cache";
    $smarty->config_dir = "/var/www/smarty/configs";

    $x="php";

    $smarty->assign('x', $x);
    $smarty->display("mytemplate.tpl");
?>

```

- Παράδειγμα Smarty κώδικα από template του webstats :

```
<title>WebStats | Apotelesmata
{if $group==NULL }
    {if $uname eq ':main'} Kentriki Selida
{else}
    {if $usrdir != NULL} {$uname} {/if}
{/if}
{else}
    {if $group eq 'all'} Server
{else} {$group}
{/if}
{/if}
</title>
```

2.4.4 Graphprite

Η Graphprite είναι μία βιβλιοθήκη ανοιχτού κώδικα γραφμένη σε PHP. Χρησιμοποιείται τη δημιουργία γραφημάτων διαφόρων τύπων τα οποία εξάγονται σε αρχεία τύπου jpg και png. Λειτουργεί με την PHP 4 και 5 ενώ απαιτείται και η βιβλιοθήκη GD 2, η χρήση της GD 1.x έχει σαν αποτέλεσμα την μείωση των δυνατοτήτων της. Το 2004 διατέθηκε η πρώτη stable έκδοση και το ίδιο έτος ενσωματώθηκε στην PEAR με το όνομα Image_Graph. Στο εργαλείο webstats χρησιμοποιείτε η 1.2, η πιο πρόσφατη έκδοση.

- Παράδειγμα κώδικα :

```
1  <?php
2      include("Graph.php");
3      // create the graph
4      $Graph =& new Image_Graph(400, 300);
5      // add a TrueType font
6      $Arial =& $Graph->addFont(new Image_Graph_Font_TTF(
7          "arial.ttf"));
8      // set the font size to 12 pixels
9      $Arial->setSize(12);
10
11     // create the plotarea
12     $Graph->add(
13         new Image_Graph_Layout_Vertical(
14             new Image_Graph_Title("GraPHPite", $Arial),
15             $Plotarea = new Image_Graph_Plotarea(),
16             5)
```

```

16      );
17
18      // create the dataset
19      $Dataset = new Image_Graph_Dataset_Trivial();
20      $Dataset->addPoint(1, 574);
21      $Dataset->addPoint(2, 239);
22      $Dataset->addPoint(3, 471);
23
24      $GridY =& $Plotarea->addGridY(new Image_Graph_Grid_Bars
25          ());
25      $GridY->setFillStyle(new Image_Graph_Fill_Gradient(
26          IMAGE_GRAPH_GRAD_VERTICAL, IMAGE_GRAPH_WHITE,
27          IMAGE_GRAPH_LIGHTGRAY, 100));
26
27      $FillArray->add(new Image_Graph_Fill_Gradient(
28          IMAGE_GRAPH_GRAD_RADIAL, IMAGE_GRAPH_BLACK,
29          IMAGE_GRAPH_WHITE, 200));
28      $FillArray->add(new Image_Graph_Fill_Gradient(
30          IMAGE_GRAPH_GRAD_RADIAL, IMAGE_GRAPH_BLUE,
31          IMAGE_GRAPH_WHITE, 200));
29      $FillArray->add(new Image_Graph_Fill_Gradient(
32          IMAGE_GRAPH_GRAD_RADIAL, IMAGE_GRAPH_ORANGE,
33          IMAGE_GRAPH_WHITE, 200));
30
31      $AxisX = & $Plotarea->getAxis(IMAGE_GRAPH_AXIS_X);
32      $AxisX->setDataPreprocessor(
33          new Image_Graph_DataPreprocessor_Array(
34              array(1=>"A", 2=>"B", 3=>"C", 4=>""))
35          )
36      );
37
38      $AxisX->setLabelInterval(1);
39      $AxisY = & $Plotarea->getAxis(IMAGE_GRAPH_AXIS_Y);
40
41      // output the Graph
42      $Graph->done();
43 ?>

```

Ο κώδικας παράγει το παρακάτω γράφημα :

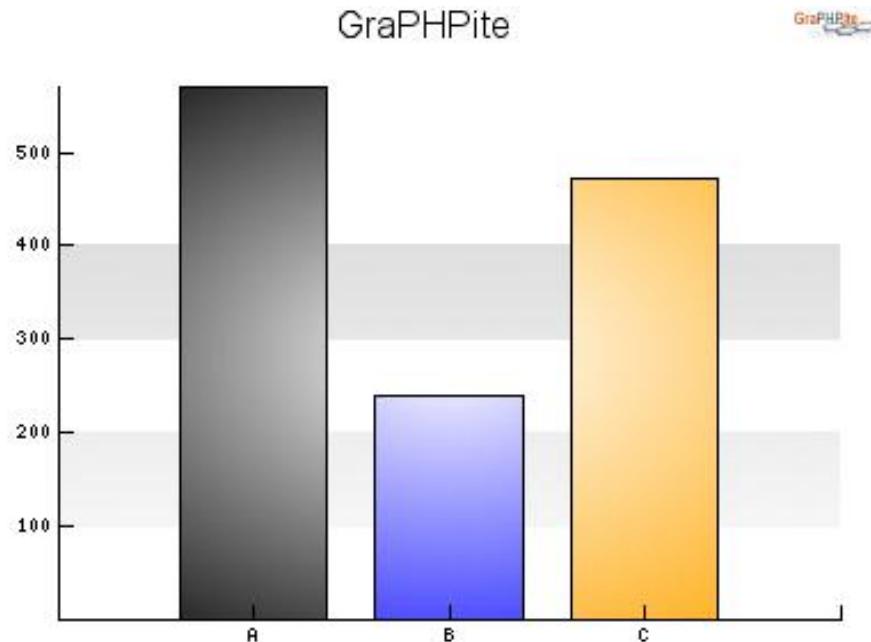


Figure 2.2: Graphpite Γράφημα

2.4.5 CSS

Cascading Style Sheets (CSS) είναι μία style language η οποία χρησιμοποιείται για να περιγράψει την εμφάνιση ενός δομημένου εγγράφου όπως η HTML. Με αυτόν τον τρόπο πετυχαίνετε μία ομοιομορφία στην εμφάνιση και στην διαμόρφωση του layout.

- Το παράδειγμα που ακολουθεί είναι από το css αρχείο της ιστοσελίδας της υπηρεσίας, για την διαμόρφωση των body, form, table και link στοιχείων.

```
body {
    margin: 0;
    background-color:#ffffff;
}

form {
    font-style : italic;
}

table {
    empty-cells : show;
```

```
}

a:link {
    color : #0887b1;
    font-family : sans-serif, Arial;
    font-size : 13px;
    text-decoration: none;
}
```

3 ΤΠΑΡΧΟΝΤΑ ΕΡΓΑΛΕΙΑ

Σε αυτό το κεφάλαιο θα αναφερθούμε σε υπάρχοντα εργαλεία που έχουν δημιουργηθεί για την ενημέρωση σχετικά με την επισκεψιμότητα σε έναν web server. Αυτά τα εργαλεία προσφέρουν counters και αναλυτικά στατιστικά μεγέθη για τον αριθμό των επισκέψεων αλλά και το πότε πραγματοποιήθηκαν. Τα παρακάτω εργαλεία δεν πληρούν τις απαιτήσεις του web server του τημήματος για το λόγο του ότι κρατούν στοιχεία μόνο για το σύνολο ενός webserver και όχι για τον κάθε χρήστη ξεχωριστά.

3.1 AWSTATS

Ένα διαδεδομένο και πολύ ισχυρό εργαλείο για την ανάλυση web στατιστικών είναι το Awstats το οποίο ανήκει στην κατηγορία του ελεύθερου λογισμικού και διανέμεται κάτω από την άδεια της GNU. Η πρώτη του έκδοση βγήκε το έτος 2000 και εξελίσσεται μέχρι και σήμερα. Είναι γραμμένο σε γλώσσα προγραμματισμού Pearl, διατίθεται για όλες τις πλατφόρμες και είναι ανοιχτού κώδικα.

Η ηλεκτρονική διεύθυνση του project είναι :

- <http://awstats.sourceforge.net/>

Τα βασικά του χαρακτηριστικά είναι :

- Λειτουργεί με τον Apache και με τις περισσότερες web/ftp/mail υπηρεσίες.
- Αναγνωρίζει πλειάδα log formats και υποστηρίζει και custom μορφή.
- Ανανεώνεται μέσω CLI αλλά και μέσω browser (CGI).
- Αναφέρει τις χώρες προέλευσης των επισκέψεων βασιζόμενο στην IP διεύθυνση και το domain name.
- Αναφέρει και φίλτραρει robots και spiders.
- Παρέχει ημερήσια, μηνιαία και ετήσια στατιστικά.
- Εξάγει στατιστικά σε pdf μορφή.

3.2 ANALOG

Ένα ακόμη εργαλείο το οποίο αναλύει web logs είναι το Analog, η πρώτη του έκδοση ανακοινώθηκε το 1995. Διατίθεται δωρεάν και υπάρχει η δυνατότητα κατεβάσματος των εκτελέσιμων αρχείων, του πηγαίου κώδικα και του το documentation. Η εφαρμογή είναι γραμμένη σε γλώσσα προγραμματισμού C και είναι διαθέσιμη για όλα τα λειτουργικά συστήματα. Επίσης έχει την δυνατότητα να παρουσιάζει αποτελέσματα σε τριανταδύο διαφορετικές γλώσσες.

Η ηλεκτρονική διεύθυνση του project είναι :

- <http://www.analog.cx>

Τα βασικά του χαρακτηριστικά είναι :

- Λειτουργεί με τον Apache web server.
- Αναγνωρίζει πλειάδα log formats και υποστηρίζει και custom μορφή.
- Ανανεώνεται μέσω CLI αλλά και μέσω browser (CGI).
- Αναφέρει τις χώρες προέλευσης των επίσκεψεων βασιζόμενο στο domain name.
- Αναφέρει και φίλτραρει robots και spiders.
- Παρέχει ημερήσια, μηνιαία και ετήσια στατιστικά.

3.3 WEBALIZER

Την τριάδα των πιο διαδεδομένων εργαλείων web στατιστικών κλείνει το Webalizer. Είναι και αυτό ελεύθερο λογισμικό ανοιχτού κώδικα και είναι γραμμένο σε γλώσσα προγραμματισμού C. Έχει επιπλέον την δυνατότητα να αναλύει αρχεία εγγραφών web logs, τα οποία είναι συμπιεσμένα σε μορφή αρχείων gzip και bzr2 απευθείας χωρίς να τα αποσυμπίεζει. Τα αποτελέσματα που παράγονται μπορούν να παρουσιαστούν σε περισσότερες από τριάντα διαφορετικές γλώσσες μεταξύ τους και τα ελληνικά.

Η ηλεκτρονική διεύθυνση του project είναι :

- <http://www.mrunix.net/webalizer/>

Τα βασικά του χαρακτηριστικά είναι :

- Λειτουργεί με τον Apache και άλλες web/ftp υπηρεσίες.
- Αναγνωρίζει πλειάδα log formats.

- Ανανεώνεται μέσω CLI.
- Αναφέρει τις χώρες προέλευσης των επίσκεψεων βασιζόμενο στο domain name.
- Παρέχει ημερήσια, μηνιαία και ετήσια στατιστικά.

3.4 ΜΕΤΡΗΤΕΣ (COUNTERS)

Παρακάτω παρουσιάζονται υπάρχοντες μετρητές για την τοποθέτηση τους σε ιστοσελίδα με σκοπό την παρουσίαση του αριθμού των επισκέψεων σε έναν ιστότοπο.

1. StatCounter

Η πρώτη εφαρμογή στην οποία θα αναφερθούμε είναι το statcounter. Διατίθεται και μία δωρεάν έκδοση και παρέχει μετρητές επισκέψεων και αναλυτικές πληροφορίες σχετικά με τις επισκέψεις σε αληθινό χρόνο.

Η εγκατάσταση του είναι εύκολη και πολύ απλή. Τα βήματα αυτά είναι η δημιουργία ενός λογαριασμού στην ιστοσελίδα της εφαρμογής και η εισαγωγή κώδικα στην ιστοσελίδα που θέλουμε να παρακολουθήσουμε. Τέλος μένει η ανάλυση των στατιστικών.

2. Addfreestats

Το Addfreestats είναι ένα ελεύθερο εργαλείο το οποίο παρέχει στους webmasters πληροφορίες για των αριθμό των επισκέψεων αλλά και στοιχεία σχετικά με τους επισκέπτες αλλά και πώς οδηγήθηκαν στην ιστοσελίδα σας. Όλα τα στοιχεία αναλύονται σε πραγματικό χρόνο.

Κάποια από τα στοιχεία τα οποία μας προσφέρει αυτό το εργαλείο είναι ένας μετρητής των συνολικών επισκέψεων αλλά και ένας ακόμα για το πόσοι είναι συνδεδεμένοι την συγκεκριμένη χρονική στιγμή.

Για την εγκατάσταση του το μόνο που χρειάζεται είναι η πρόσθεση κώδικα στην ιστοσελίδα.

3. GoStats

Το Gostats είναι ένα ελεύθερο εργαλείο το οποίο πέραν των μετρητών παρέχει πληροφορίες και για τις εμφανίσεις των ιστοσελίδων ενός ιστότοπου, τους επισκέπτες και την επισκεψιμότητα για μία χρονική περίοδο της επιλογής μας.

Παρέχει σχεδιαγράμματα σχετικά με την κίνηση και εμφανίζει στον παγκόσμιο χάρτη τα σημεία από τα οποία έγιναν οι επισκέψεις. Πέραν αυτών προσφέρει διάφορα στατιστικά στοιχεία όπως μέγιστες και ελάχιστες επισκέψεις και εμφανίζει την κατάταξη των ιστοσελίδων του ιστότοπου, με τις περισσότερες επισκέψεις.

Η εγκατάσταση του είναι ίδια με των προηγούμενων εργαλείων, απλώς προσθέτετε ένα κομμάτι κώδικα στην ιστοσελίδα.

4. Site Meter

To Site Meter είναι μία υπηρεσία στατιστικών web κίνησης. Η basic έκδοση του διατίθεται δωρεάν και ενημερώνει αναλυτικά σχετικά με τις επισκέψεις, τους επισκέπτες και δίνει την δυνατότητα της εμφάνισης ενός counter σε ιστοσελίδα. Επίσης παρουσιάζει στοιχεία και στατιστικά μεγέθει σχετικά με τις επισκέψεις στον ιστότοπο.

Η εφαρμογή διαχωρίζει τις εμφανίσεις ιστοσελίδων από την επισκέψη στον ιστότοπο και ενημερώνει για αυτές το ίδιο αναλυτικά με τις επισκέψεις.

4 ΔΟΜΗ / ΑΝΑΛΥΣΗ

Η δομή της εφαρμογής webstats είναι πολύ απλή και αποτελείται από τρία στοιχεία. Σε αυτό το κεφάλαιο παρουσιάζονται και στη συνέχεια αναλύονται το καθένα από αυτά.

- Parser : Ο parser είναι το πρόγραμμα που σαρώνει το αρχείο access.log του Apache το οποίο περιέχει εγγραφές με τις επισκέψεις στον web server. Έτσι αντλούνται όλες αυτές οι πληροφορίες που χρειάζονται για τον υπολογισμό στατιστικών για την επισκεψιμότητα στον aetos. Στη συνέχεια όλες αυτές οι εγγραφές αποθηκεύονται σε μία βάση δεδομένων. Οι ενημερώσεις και οι διαγραφές στη βάση εκτελούνται από τον parser. Η εκτέλεση του parser γίνεται από ένα σενάριο φλοιού Unix το οποίο εκτελείται ανά τακτά χρονικά διαστήματα με τη βοήθεια ενός scheduler προγράμματος, του Cron.
- Web Interface : Η διασύνδεση της υπηρεσίας με τον χρήστη γίνεται μέσω μιας δυναμικής ιστοσελίδας που δημιουργήθηκε για την παρουσίαση στατιστικών. Αυτά είναι είτε κάποια αριθμητικά μεγέθη είτε σχεδιαγράμματα τα οποία προκύπτουν από ερωτήματα που εκτελούνται στη βάση μετά από σύνδεση του web interface με αυτή.
- Βάση Δεδομένων : Η βάση ουσιαστικά είναι το ενδιάμεσο και συνδετικό στοιχείο σε αυτά που αναφέρθηκαν παραπάνω. Στους πίνακες της βάσης είναι αποθηκευμένες όλες οι απαιτούμενες πληροφορίες όπως οι λογαριασμοί των χρηστών του server και οι επισκέψεις για ορισμένα χρονικά διαστήματα. Σε αυτήν συνδέονται ο parser και το web interface, το πρώτο για να την ενημερώσει και το δεύτερο για την εκτέλεση ερωτημάτων για τον υπολογισμό στατιστικών.

4.1 ΓΛΩΣΣΕΣ ΤΛΟΠΟΙΗΣΗΣ

Για την υλοποίηση αυτών των τριών δομικών στοιχείων που αναφέρθηκαν παραπάνω χρησιμοποιήθηκαν εργαλεία όπως γλώσσες προγραμματισμού και συστήματα διαχείρησης βάσεων δεδομένων. Αυτά παρουσιάζονται παρακάτω.

4.1.1 Parser

Η υλοποίηση του Parser έγινε με τη γλώσσα προγραμματισμού python. Η γλώσσα αυτή είναι multiplatform, το συντακτικό της είναι αρκετά απλό και λιτό χαρακτηριστικό που την κάνει αρκετά εύχρηστη και εύκολη στην εκμάθηση της. Είναι μία γλώσσα που μπορεί να υποστηρίξει

πολλά προγραμματιστικά στυλ και είναι πολύ γρήγορη. Οι παραπάνω λόγοι την καθιστούν μία πρακτική γλώσσα και αν και είναι υψηλού επιπέδου ενδείκνυται για πιο low-level εφαρμογές.

Για την σύνδεση της `python` με την PostgreSQL χρησιμοποιήθηκε η βιβλιοθήκη `pyPgSQL` η οποία μας προσφέρει ένα interface μεταξύ αυτών των δύο ώστε να μπορούμε να εκτελούμε εισαγωγές, ενημερώσεις και διαγραφές στην βάση από τον parser. Για την χρήση αυτής της βιβλιοθήκης όμως πρέπει η έκδοση της PostgreSQL να είναι η 7.0 ή νεότερη ώστε να είναι δυνατή η σύνδεση.

4.1.2 Βάση Δεδομένων

Όσον αφορά την βάση δεδομένων χρησιμοποιήσαμε την PostgreSQL, ένα σύστημα διαχείρισης βάσεων δεδομένων ανοιχτού κώδικα. Αυτή η υπηρεσία είναι διαθέσιμη στο server του τμήματος και στο διαδίκτυο υπάρχει μία μεγάλη κοινότητα που το υποστηρίζει και προσφέρει σημαντικά βοηθήματα.

Αρχικά υπήρξε σαν εναλλακτική επιλογή `SQLite` η οποία τρέχει τοπικά, χρησιμοποιεί ελάχιστους υπολογιστικούς πόρους, είναι πολύ γρήγορη και υπάρχει και η δυνατότητα σύνδεσης της με την `python`. Το γεγονός όμως ότι δεν υπάρχει η δυνατότητα να λειτουργήσει δικτυακά, απέτρεψε την επιλογή της.

4.1.3 Web Interface

Το layout της ιστοσελίδας διαμορφώθηκε χρησιμοποιώντας `stylesheets` ώστε να υπάρχει ομοιομορφία στην εμφάνιση.

Για το side server programming χρησιμοποιήθηκε η PHP, μία γλώσσα που διατίθεται δωρεάν και δίνει την δυνατότητα δημιουργίας ιστοσελίδων με δυναμικό περιεχόμενο, επίσης είναι διαθέσιμο ένα πλούσιο documentation στο διαδίκτυο. Για την δημιουργία διασύνδεσης μεταξύ της PHP και της PostgreSQL χρησιμοποιήθηκε η βιβλιοθήκη `rphr-pgsql`.

Η εμφάνιση των αποτελεσμάτων που προκύπτουν από την εκτέλεση των `rphr` αρχείων έγινε με τη χρήση του `Smarty`, μία μηχανή `templates` για `rphr` αρχεία. Έτσι διαχωρίστηκε το λειτουργικό μέρος από αυτό της εμφάνισης.

4.2 ΣΧΗΜΑ ΒΑΣΗΣ

Το πρώτο πράγμα που έπρεπε να σχεδιαστεί ουσιαστικά ήταν το σχήμα της βάσεις. Πάνω σε αυτό όμως προσαρμοζόταν και ο parser εφόσον αυτό το αρχείο όμως εκτελούσε τις εισαγωγές, τις ενημερώσεις και της διαγραφές. Τα διακριτά αντικείμενα που υπήρχαν ήταν δύο, οι λογαριασμοί του `aetos` που είχαν ανεβάσει ιστοσελίδες και οι επισκέψεις. Για καλύτερη χρήση της πληροφορίας αλλά και για να μειωθεί ο όγκος της βάσης ο πίνακας επισκέψεις διασπάστηκε σε τρεις.

Αυτοί οι πίνακες είναι ο επισκέψεις ανά ώρα, ανά μέρα και επισκέψεις ανά μήνα. Οι πρώτοι δύο κρατάνε εγγραφές για ένα μικρό χρονικό διάστημα, τόσο ώστε να μπορεί να παρουσιαστεί

η κίνηση τις τελευταίες ώρες και μέρες αντίστοιχα. Η διάσπαση στον πίνακα των επισκέψεων έγινε αναλύοντας το πεδίο της ημερομηνίας, έτσι επετεύχθη μία καλύτερη χρήση της πληροφορίας αποφεύγοντας χρονοβόρες προσπελάσεις και πράξεις για το σύστημα διαχείρισης της βάσης και μειώθηκε σημαντικά ο όγκος. Επιπλέον δημιουργήθηκε ένας ακόμα πίνακας που κρατάει εγγραφές για τις επισκέψεις ανά ώρα και μήνα για κάθε λογαριασμό ώστε να υπάρχει δυνατότητα να υπολογίζεται η κατανομή των επισκέψεων ανά ώρα σε βάθος εώς και ενός χρόνου.

Ο πίνακας usrdir κρατάει εγγραφές με τους λογαριασμούς που έχουν ανεβάσει ιστοσελίδες στο server και έχει τα παρακάτω πεδία.

- Πρωτεύον κλειδί είναι το id, είναι ένα τεχνητό κλειδί που παίρνει μοναδικές τιμές από ένα sequence που δημιουργήθηκε στη βάση και είναι ο αριθμός ταυτότητα του λογαριασμού.
- Το πεδίο upname που αντιστοιχεί στο όνομα του λογαριασμού.
- Το πεδίο directory για το path του home directory του λογαριασμού.
- Το πεδίο group για την κατηγορία που ανήκει ο λογαριασμός.

Άν και κάθε φορά υπάρχει μόνο ένας λογαριασμός που αντιστοιχεί σε κάποιο όνομα επειδή υπάρχει η περίπτωση όπου ένας λογαριασμός διαγράφεται και δημιουργείται ένας καινούργιος με το ίδιο όνομα για αυτό το λόγο δεν δηλώνεται UNIQUE. Βέβαια όταν ένας λογαριασμός έχει διαγραφεί στην επόμενη εκτέλεση του parser θα διαγραφεί και από τη βάση όμως ίσως υπάρχουν κάποιες ακραίες περιπτώσεις όπου θα συνυπάρχουν αυτοί οι δύο λογαριασμοί στη βάση.

Όσον αφορά το πεδίο directory δηλώνεται UNIQUE για ασφάλεια αφού είναι μοναδικό για κάθε λογαριασμό λόγω της οργάνωσης των λογαριασμών στο server του τμήματος. Με αυτήν τη δήλωση είναι σαν να έχουμε ένα ακόμα πεδίο κλειδί για τις εγγραφές του πίνακα usrdir.

Τέλος έχουμε το πεδίο ugroup που αντιπροσωπεύει την ομάδα του λογαριασμού. Οι λογαριασμοί στον aetos χωρίζονται σε staff και students, δηλαδή σε αυτές του προσωπικού του τμήματος όπως οι καθηγητές και σε αυτές των φοιτητών. Προσθέσαμε αυτό το πεδίο για να έχουμε την δυνατότητα να υπολογίσουμε κάποια στατιστικά μεγέθη σχετικά με αυτές τις κατηγορίες. Πέραν αυτών των δύο δημιουργήθηκε μία επιπλέον, η κατηγορία other για να εντάξουμε σε αυτήν το root document του server, δηλαδή τη σελίδα του τμήματος αλλά και για να καλύψουμε κάποια νέα κατηγορία που ίσως προκύψει στο μέλλον. Σε ποιά κατηγορία ανήκει ένας λογαριασμός προκύπτει από το home directory τους βάση της πολιτικής που εφαρμόζεται για την οργάνωση και κατηγοριοποίηση των λογαριασμών στο server του τμήματος.

Οι πίνακες hpm, hpd, hph, δηλαδή αυτοί που κρατούν εγγραφές με τις επισκέψεις ανά μήνα, μέρα και ώρα αντίστοιχα έχουν τα πεδία hits, δηλαδή των αριθμό των επισκέψεων και data για τον αριθμό των δεδομένων που έχουν κατέβει από τις επισκέψεις. Τον όγκο των δεδομένων των κρατάμε σε Kilobytes. Για τον πίνακα που κρατάει εγγραφές ανά μήνα υπάρχουν επιπλέον τα πεδία month για το μήνα και year για τον χρόνο. Για τον ανά ώρα και μέρα έχουμε το

πεδίο date για την ημερομηνία. Επιπλέον υπάρχει το πεδίο hour για την ώρα στο πίνακα με τις επισκέψεις ανά ώρα.

Αυτοί οι τρεις πίνακες έχουν ακόμα τα πεδία uid και ts. Το uid είναι ξένο κλειδί και αναφέρεται στο πεδίο id του πίνακα usrdir. Χρησιμοποιείτε για την δημιουργία συσχέτισης ένα προς πολλά μεταξύ του πίνακα των χρηστών και των πινάκων των επισκέψεων, έτσι ώστε να αντιστοιχηθεί μία επίσκεψη με τον ιστότοπο ενός λογαριασμού. Το πεδίο ts είναι τύπου timestamp και είναι το κριτήριο για την διαγραφή των εγγραφών, εφόσον η διάρκεια ζωή τους έχει λήξη. Οι εγγραφές του πίνακα των επισκέψεων ανά μήνα έχουν διάρκεια πέντε χρόνων αυτή η χρονική διάρκεια θεωρήθηκε αφκετή για την εξαγωγή ασφαλών συμπερασμάτων, αυτό είναι και το μέγιστο βάθος χρόνου στατιστικών στοιχείων της υπηρεσίας. Για τους άλλους δύο πίνακες, ανά μέρες και ώρες, οι εγγραφές έχουν διάρκεια τριανταμία μέρες και εικοσιτέσσερις ώρες αντίστοιχα. Αυτοί χρησιμοποιούνται για την παρουσιάση της κίνησης το τελευταίο χρονικό διάστημα για αυτό και η τόσο μικρή διάρκεια ζωής.

Πέραν αυτών των τριών πινάκων για τις επισκέψεις υπάρχει ακόμα ένας με το όνομα hhm. Η χρήση του είναι για τον υπολογισμό της κατανομής των επισκέψεων ανά ώρα. Τα πεδία που έχει είναι το uid (που αναφέρεται στον πίνακα usrdir), πεδία για τον μήνα, έτος, ώρα, αριθμό επισκέψεων και ένα πεδίο τύπου timestamp για την διαγράφη των εγγραφών παλαιότερων από δώδεκα μήνες. Αυτός ο πίνακας δίνει την δυνατότητα της ενημέρωσης για τον τρόπο που κατανέμεται η επισκεψιμότητα στην διάρκεια της ημέρας σε βάθος εώς και ενός χρόνου.

Τέλος δημιουργήθηκε μια αυξανόμενη κατά ένα ακολουθία (sequence) με το όνομα seq_usrdir_id για να δίνει μοναδικές τιμές στο πεδίο id, κλειδί του πίνακα usrdir.

4.2.1 Πίνακες Βάσης

Παρακάτω παρουσιάζονται οι πίνακες της βάσης.

USRDIR (λογαριασμοί χρηστών του server)

id	integer	πρωτεύων κλειδί
uname	varchar	
directory	varchar	unique
ugroup	varchar(7)	

HPM (επισκέψεις ανά μήνα)

uid	integer	κλειδί	αναφέρεται στο usrdir(id)
month	integer	κλειδί	
year	integer	κλειδί	
hits	integer		
data	integer		
ts	timestamp		

HPD(επισκέψεις ανά μέρα)

uid	integer	κλειδί	αναφέρεται στο usrdir(id)
date	date	κλειδί	
hits	integer		
data	integer		
ts	timestamp		

HPH (επισκέψεις ανά ώρα)

uid	integer	κλειδί	αναφέρεται στο usrdir(id)
hour	integer	κλειδί	
date	date	κλειδί	
hits	integer		
data	integer		
ts	timestamp		

HHM (κατανομή των επισκέψεων ανά ώρα)

uid	integer	κλειδί	αναφέρεται στο usrdir(id)
hour	integer	κλειδί	
month	integer	κλειδί	
year	integer	κλειδί	
hits	integer		
ts	timestamp		

Τα πεδία που συμμετέχουν στα σύνθετα κλειδιά δηλώθηκαν NOT NULL. Επίσης για τα πεδία hour και month δημιουργήθηκαν constraints ώστε να αποτρέπεται μία μη αποδεκτή τιμή. Επίσης δημιουργήθηκε constraint για το πεδίο ugroup ώστε να δέχεται τις αποδεκτές τιμές staff, student και other.

Για τα ζένα κλειδιά που αναφέρονται στο id του πίνακα usrdir δηλώθηκαν cascades ύστι ώστε να επηρεάζονται από τις μεταβολές που θα γίνονται στην εγγραφή που αναφέρονται.

4.2.2 SQL κώδικας δημιουργίας των tables

Παρακάτω παρατίθεται ο SQL κώδικας που δημιουργεί τους πίνακες στη βάση. Ο κώδικας αυτός είναι το περιεχόμενο του αρχείου webstats_tables.sql.

```

1 CREATE TABLE usrdir (
2     id INTEGER PRIMARY KEY ,
3     uname VARCHAR ,
4     directory VARCHAR UNIQUE ,
5     ugroup VARCHAR(7) CONSTRAINT c_ugroup
6             CHECK (ugroup in ('staff', 'student', 'other'))
7 );
8
9
10
11
12
13
14
15
16
17
18
19
20
21
22
23
24
25
26
27
28
29
30
31
32
33
34
35
36
37
38
39
40
41
42
43
44
45
46
47
48
49
50
51
52
53
54
55
56
57
58
59
60
61
62
63
64
65
66
67
68
69
70
71
72
73
74
75
76
77
78
79
80
81
82
83
84
85
86
87
88
89
90
91
92
93
94
95
96
97
98
99
100
101
102
103
104
105
106
107
108
109
110
111
112
113
114
115
116
117
118
119
120
121
122
123
124
125
126
127
128
129
130
131
132
133
134
135
136
137
138
139
140
141
142
143
144
145
146
147
148
149
150
151
152
153
154
155
156
157
158
159
160
161
162
163
164
165
166
167
168
169
170
171
172
173
174
175
176
177
178
179
180
181
182
183
184
185
186
187
188
189
190
191
192
193
194
195
196
197
198
199
200
201
202
203
204
205
206
207
208
209
210
211
212
213
214
215
216
217
218
219
220
221
222
223
224
225
226
227
228
229
230
231
232
233
234
235
236
237
238
239
240
241
242
243
244
245
246
247
248
249
250
251
252
253
254
255
256
257
258
259
260
261
262
263
264
265
266
267
268
269
270
271
272
273
274
275
276
277
278
279
280
281
282
283
284
285
286
287
288
289
290
291
292
293
294
295
296
297
298
299
300
301
302
303
304
305
306
307
308
309
310
311
312
313
314
315
316
317
318
319
320
321
322
323
324
325
326
327
328
329
330
331
332
333
334
335
336
337
338
339
340
341
342
343
344
345
346
347
348
349
350
351
352
353
354
355
356
357
358
359
360
361
362
363
364
365
366
367
368
369
370
371
372
373
374
375
376
377
378
379
380
381
382
383
384
385
386
387
388
389
390
391
392
393
394
395
396
397
398
399
400
401
402
403
404
405
406
407
408
409
410
411
412
413
414
415
416
417
418
419
420
421
422
423
424
425
426
427
428
429
430
431
432
433
434
435
436
437
438
439
440
441
442
443
444
445
446
447
448
449
450
451
452
453
454
455
456
457
458
459
460
461
462
463
464
465
466
467
468
469
470
471
472
473
474
475
476
477
478
479
480
481
482
483
484
485
486
487
488
489
490
491
492
493
494
495
496
497
498
499
500
501
502
503
504
505
506
507
508
509
510
511
512
513
514
515
516
517
518
519
520
521
522
523
524
525
526
527
528
529
530
531
532
533
534
535
536
537
538
539
540
541
542
543
544
545
546
547
548
549
550
551
552
553
554
555
556
557
558
559
559
560
561
562
563
564
565
566
567
568
569
569
570
571
572
573
574
575
576
577
578
579
579
580
581
582
583
584
585
586
587
587
588
589
589
590
591
592
593
594
595
596
597
597
598
599
599
600
601
602
603
604
605
605
606
607
607
608
609
609
610
611
611
612
612
613
613
614
614
615
615
616
616
617
617
618
618
619
619
620
620
621
621
622
622
623
623
624
624
625
625
626
626
627
627
628
628
629
629
630
630
631
631
632
632
633
633
634
634
635
635
636
636
637
637
638
638
639
639
640
640
641
641
642
642
643
643
644
644
645
645
646
646
647
647
648
648
649
649
650
650
651
651
652
652
653
653
654
654
655
655
656
656
657
657
658
658
659
659
660
660
661
661
662
662
663
663
664
664
665
665
666
666
667
667
668
668
669
669
670
670
671
671
672
672
673
673
674
674
675
675
676
676
677
677
678
678
679
679
680
680
681
681
682
682
683
683
684
684
685
685
686
686
687
687
688
688
689
689
690
690
691
691
692
692
693
693
694
694
695
695
696
696
697
697
698
698
699
699
700
700
701
701
702
702
703
703
704
704
705
705
706
706
707
707
708
708
709
709
710
710
711
711
712
712
713
713
714
714
715
715
716
716
717
717
718
718
719
719
720
720
721
721
722
722
723
723
724
724
725
725
726
726
727
727
728
728
729
729
730
730
731
731
732
732
733
733
734
734
735
735
736
736
737
737
738
738
739
739
740
740
741
741
742
742
743
743
744
744
745
745
746
746
747
747
748
748
749
749
750
750
751
751
752
752
753
753
754
754
755
755
756
756
757
757
758
758
759
759
760
760
761
761
762
762
763
763
764
764
765
765
766
766
767
767
768
768
769
769
770
770
771
771
772
772
773
773
774
774
775
775
776
776
777
777
778
778
779
779
780
780
781
781
782
782
783
783
784
784
785
785
786
786
787
787
788
788
789
789
790
790
791
791
792
792
793
793
794
794
795
795
796
796
797
797
798
798
799
799
800
800
801
801
802
802
803
803
804
804
805
805
806
806
807
807
808
808
809
809
810
810
811
811
812
812
813
813
814
814
815
815
816
816
817
817
818
818
819
819
820
820
821
821
822
822
823
823
824
824
825
825
826
826
827
827
828
828
829
829
830
830
831
831
832
832
833
833
834
834
835
835
836
836
837
837
838
838
839
839
840
840
841
841
842
842
843
843
844
844
845
845
846
846
847
847
848
848
849
849
850
850
851
851
852
852
853
853
854
854
855
855
856
856
857
857
858
858
859
859
860
860
861
861
862
862
863
863
864
864
865
865
866
866
867
867
868
868
869
869
870
870
871
871
872
872
873
873
874
874
875
875
876
876
877
877
878
878
879
879
880
880
881
881
882
882
883
883
884
884
885
885
886
886
887
887
888
888
889
889
890
890
891
891
892
892
893
893
894
894
895
895
896
896
897
897
898
898
899
899
900
900
901
901
902
902
903
903
904
904
905
905
906
906
907
907
908
908
909
909
910
910
911
911
912
912
913
913
914
914
915
915
916
916
917
917
918
918
919
919
920
920
921
921
922
922
923
923
924
924
925
925
926
926
927
927
928
928
929
929
930
930
931
931
932
932
933
933
934
934
935
935
936
936
937
937
938
938
939
939
940
940
941
941
942
942
943
943
944
944
945
945
946
946
947
947
948
948
949
949
950
950
951
951
952
952
953
953
954
954
955
955
956
956
957
957
958
958
959
959
960
960
961
961
962
962
963
963
964
964
965
965
966
966
967
967
968
968
969
969
970
970
971
971
972
972
973
973
974
974
975
975
976
976
977
977
978
978
979
979
980
980
981
981
982
982
983
983
984
984
985
985
986
986
987
987
988
988
989
989
990
990
991
991
992
992
993
993
994
994
995
995
996
996
997
997
998
998
999
999
1000
1000
1001
1001
1002
1002
1003
1003
1004
1004
1005
1005
1006
1006
1007
1007
1008
1008
1009
1009
1010
1010
1011
1011
1012
1012
1013
1013
1014
1014
1015
1015
1016
1016
1017
1017
1018
1018
1019
1019
1020
1020
1021
1021
1022
1022
1023
1023
1024
1024
1025
1025
1026
1026
1027
1027
1028
1028
1029
1029
1030
1030
1031
1031
1032
1032
1033
1033
1034
1034
1035
1035
1036
1036
1037
1037
1038
1038
1039
1039
1040
1040
1041
1041
1042
1042
1043
1043
1044
1044
1045
1045
1046
1046
1047
1047
1048
1048
1049
1049
1050
1050
1051
1051
1052
1052
1053
1053
1054
1054
1055
1055
1056
1056
1057
1057
1058
1058
1059
1059
1060
1060
1061
1061
1062
1062
1063
1063
1064
1064
1065
1065
1066
1066
1067
1067
1068
1068
1069
1069
1070
1070
1071
1071
1072
1072
1073
1073
1074
1074
1075
1075
1076
1076
1077
1077
1078
1078
1079
1079
1080
1080
1081
1081
1082
1082
1083
1083
1084
1084
1085
1085
1086
1086
1087
1087
1088
1088
1089
1089
1090
1090
1091
1091
1092
1092
1093
1093
1094
1094
1095
1095
1096
1096
1097
1097
1098
1098
1099
1099
1100
1100
1101
1101
1102
1102
1103
1103
1104
1104
1105
1105
1106
1106
1107
1107
1108
1108
1109
1109
1110
1110
1111
1111
1112
1112
1113
1113
1114
1114
1115
1115
1116
1116
1117
1117
1118
1118
1119
1119
1120
1120
1121
1121
1122
1122
1123
1123
1124
1124
1125
1125
1126
1126
1127
1127
1128
1128
1129
1129
1130
1130
1131
1131
1132
1132
1133
1133
1134
1134
1135
1135
1136
1136
1137
1137
1138
1138
1139
1139
1140
1140
1141
1141
1142
1142
1143
1143
1144
1144
1145
1145
1146
1146
1147
1147
1148
1148
1149
1149
1150
1150
1151
1151
1152
1152
1153
1153
1154
1154
1155
1155
1156
1156
1157
1157
1158
1158
1159
1159
1160
1160
1161
1161
1162
1162
1163
1163
1164
1164
1165
1165
1166
1166
1167
1167
1168
1168
1169
1169
1170
1170
1171
1171
1172
1172
1173
1173
1174
1174
1175
1175
1176
1176
1177
1177
1178
1178
1179
1179
1180
1180
1181
1181
1182
1182
1183
1183
1184
1184
1185
1185
1186
1186
1187
1187
1188
1188
1189
1189
1190
1190
1191
1191
1192
1192
1193
1193
1194
1194
1195
1195
1196
1196
1197
1197
1198
1198
1199
1199
1200
1200
1201
1201
1202
1202
1203
1203
1204
1204
1205
1205
1206
1206
1207
1207
1208
1208
1209
1209
1210
1210
1211
1211
1212
1212
1213
1213
1214
1214
1215
1215
1216
1216
1217
1217
1218
1218
1219
1219
1220
1220
1221
1221
1222
1222
1223
1223
1224
1224
1225
1225
1226
1226
1227
1227
1228
1228
1229
1229
1230
1230
1231
1231
1232
1232
1233
1233
1234
1234
1235
1235
1236
1236
1237
1237
1238
1238
1239
1239
1240
1240
1241
1241
1242
1242
1243
1243
1244
1244
1245
1245
1246
1246
1247
1247
1248
1248
1249
1249
1250
1250
1251
1251
1252
1252
1253
1253
1254
1254
1255
1255
1256
1256
1257
1257
1258
1258
1259
1259
1260
1260
1261
1261
1262
1262
1263
1263
1264
1264
1265
1265
1266
1266
1267
1267
1268
1268
1269
1269
1270
1270
1271
1271
1272
1272
1273
1273
1274
1274
1275
1275
1276
1276
1277
1277
1278
1278
1279
1279
1280
1280
1281
1281
1282
1282
1283
1283
1284
1284
1285
1285
1286
1286
1287
1287
1288
1288
1289
1289
1290
1290
1291
1291
1292
1292
1293
1293
1294
1294
1295
1295
1296
1296
1297
1297
1298
1298
1299
1299
1300
1300
1301
1301
1302
1302
1303
1303
1304
1304
1305
1305
1306
1306
1307
1307
1308
1308
1309
1309
1310
1310
1311
1311
1312
1312
1313
1313
1314
1314
1315
1315
1316
1316
1317
1317
1318
1318
1319
1319
1320
1320
1321
1321
1322
1322
1323
1323
1324
1324
1325
1325
1326
1326
1327
1327
1328
1328
1329
1329
1330
1330
1331
1331
1332
1332
1333
1333
1334
1334
1335
1335
1336
1336
1337
1337
1338
1338
1339
1339
1340
1340
1341
1341
1342
1342
1343
1343
1344
1344
1345
1345
1346
1346
1347
1347
1348
1348
1349
1349
1350
1350
1351
1351
1352
1352
1353
1353
1354
1354
1355
1355
1356
1356
1357
1357
1358
1358
1359
1359
1360
1360
1361
1361
1362
1362
1363
1363
1364
1364
1365
1365
1366
1366
1367
1367
1368
1368
1369
1369
1370
1370
1371
1371
1372
1372
1373
1373
1374
1374
1375
1375
1376
1376
1377
1377
1378
1378
1379
1379
1380
1380
1381
1381
1382
1382
1383
1383
1384
1384
1385
1385
1386
1386
1387
1387
1388
1388
1389
1389
1390
1390
1391
1391
1392
1392
1393
1393
1394
1394
1395
1395
1396
1396
1397
1397
1398
1398
1399
1399
1400
1400
1401
1401
1402
1402
1403
1403
1404
1404
1405
1405
1406
1406
1407
1407
1408
1408
1409
1409
1410
1410
1411
1411
1412
1412
1413
1413
1414
1414
1415
1415
1416
1416
1417
1417
1418
1418
1419
1419
1420
1420
1421
1421
1422
1422
1423
1423
1424
1424
1425
1425
1426
1426
1427
1427
1428
1428
1429
1429
1430
1430
1431
1431
1432
1432
1433
1433
1434
1434
1435
1435
1436
1436
1437
1437
1438
1438
1439
1439
1440
1440
1441
1441
1442
1442
1443
1443
1444
1444
1445
1445
1446
1446
1447
1447
1448
1448
1449
1449
1450
1450
1451
1451
1452
1452
1453
1453
1454
1454
1455
1455
1456
1456
1457
1457
1458
1458
1459
1459
1460
1460
1461
1461
1462
1462
1463
1463
1464
1464
1465
1465
1466
1466
1467
1467
1468
1468
1469
1469
1470
1470
1471
1471
1472
1472
1473
1473
1474
1474
1475
1475
1476
1476
1477
1477
1478
1478
1479
1479
1480
1480
1481
1481
1482
1482
1483
1483
1484
1484
1485
1485
1486
1486
1487
1487
1488
1488
1489
1489
1490
1490
1491
1491
1492
1492
1493
1493
1494
1494
1495
1495
1496
1496
1497
1497
1498
1498
1499
1499
1500
1500
1501
1501
1502
1502
1503
1503
1504
1504
1505
1505
1506
1506
1507
1507
1508
1508
1509
1509
1510
1510
1511
1511
1512
1512
1513
1513
1514
1514
1515
1515

```

```

1 CREATE TABLE hpd (
2     uid INTEGER REFERENCES usrdir(id)
3         ON UPDATE CASCADE
4         ON DELETE CASCADE,
5     date DATE NOT NULL ,
6     hits INTEGER ,
7     data INTEGER ,
8     ts TIMESTAMP DEFAULT CURRENT_TIMESTAMP ,
9     PRIMARY KEY (uid, date)
10 );

```

```

1 CREATE TABLE hpm (
2     uid INTEGER REFERENCES usrdir(id)
3         ON UPDATE CASCADE
4         ON DELETE CASCADE,
5     month INTEGER NOT NULL CONSTRAINT c_month
6         CHECK (month>0 AND month<=12) ,
7     year INTEGER NOT NULL ,
8     hits INTEGER ,
9     data INTEGER ,
10    ts TIMESTAMP DEFAULT CURRENT_TIMESTAMP ,
11    PRIMARY KEY (uid, month, year)
12 );

```

```

1 CREATE TABLE hhm (
2     uid INTEGER REFERENCES usrdir(id)
3         ON UPDATE CASCADE
4         ON DELETE CASCADE,
5     month INTEGER NOT NULL CONSTRAINT c2_month
6         CHECK (month>0 AND month<=12) ,
7     hour INTEGER NOT NULL CONSTRAINT c2_hour
8         CHECK (hour>=0 AND hour<24) ,
9     year INTEGER NOT NULL ,
10    hits INTEGER ,
11    ts TIMESTAMP DEFAULT CURRENT_TIMESTAMP ,
12    PRIMARY KEY (uid, month, year, hour)
13 );

```

Τέλος ο κώδικας για τη δημιουργία μιας ακολουθίας για την απόδοση τιμής στο id, το πεδίο κλειδί του πίνακα usrdir.

```
CREATE SEQUENCE seq_usrdir_id ;
```

4.2.3 Σχεδιάγραμμα ER της Βάσης

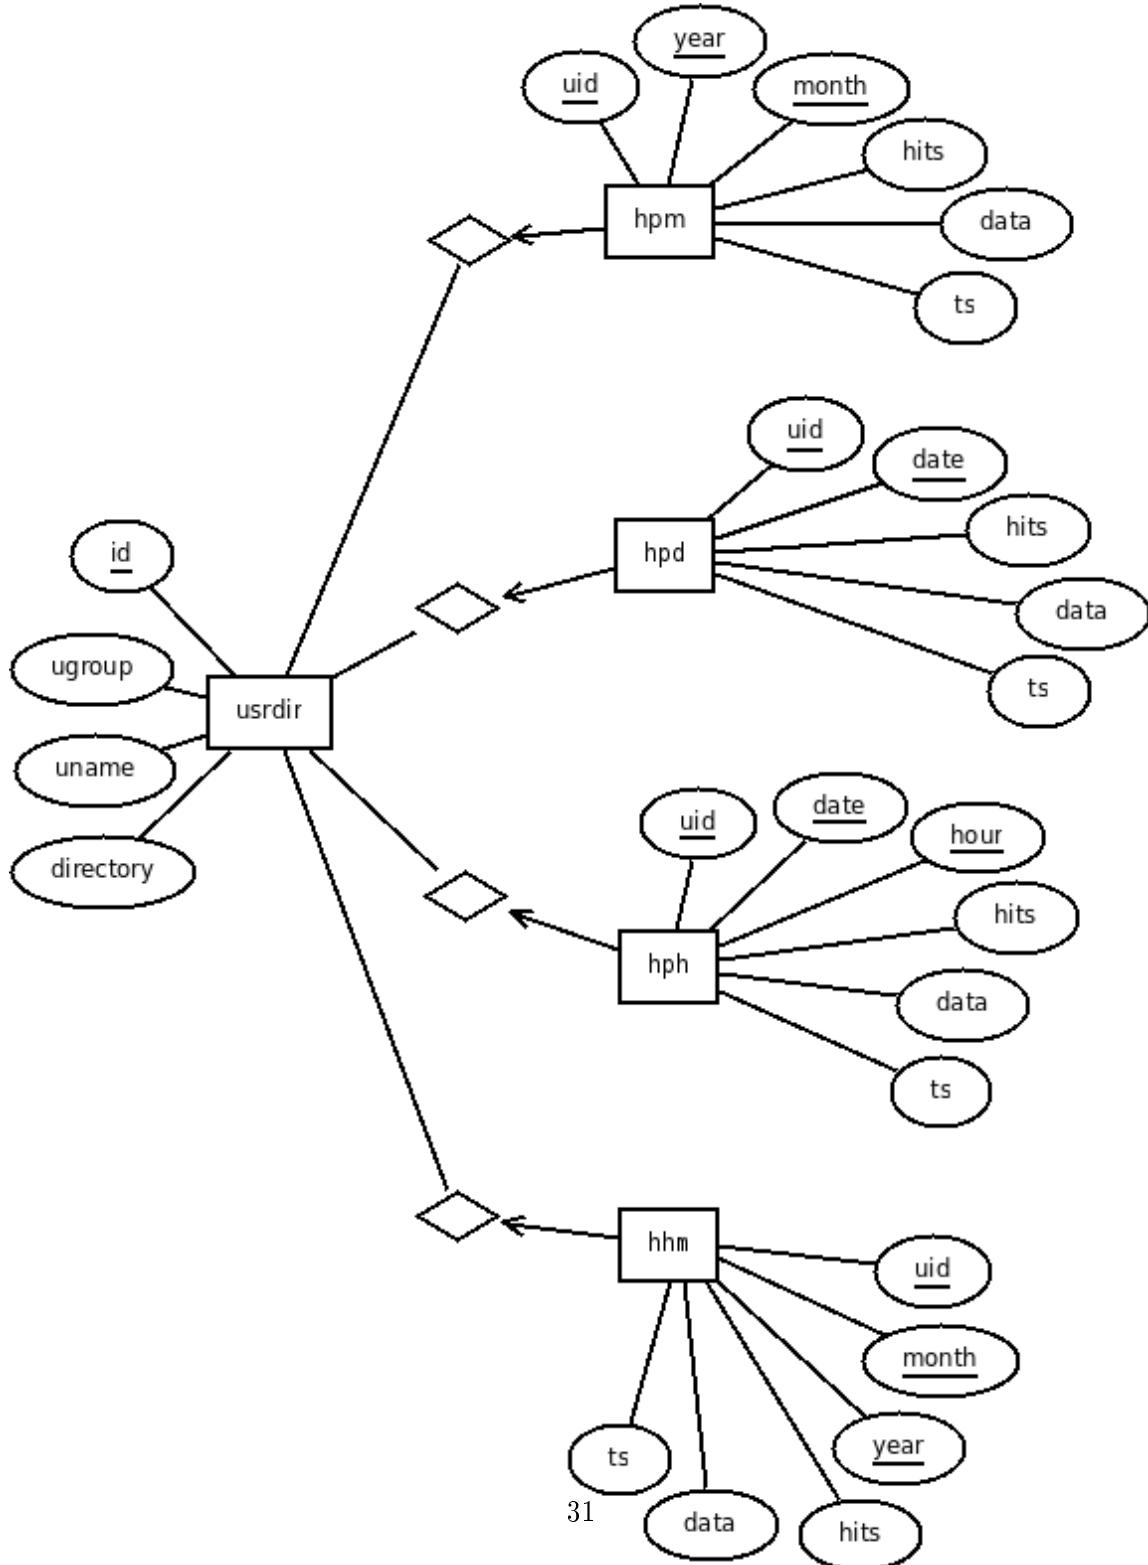


Figure 4.1: Σχεδιάγραμμα ER

5 ΑΝΑΛΥΣΗ ΚΩΔΙΚΑ

5.1 LAUNCHER.SH

Το αρχείο launcher.sh είναι ένα σενάριο φλοιού το οποίο εκτελείτε προγραμματισμένα κάθε δεκαπέντε λεπτά με την χρήση του Cron. Έτσι παραμένει ενήμερη η βάση δεδομένων της υπηρεσίας για τις νέες επισκέψεις που πραγματοποιήθηκαν.

Αρχικά εκτελείτε η logtail η οποία διαβάζει τις νέες εγγραφές του αρχείου access.log που περιέχει τα logs των επισκέψεων, το αποτέλεσμα αυτής της ενέργειας διοχετεύεται σε ένα αρχείο με το όνομα feed. Στην συνέχεια εκτελείται από το σενάριο ο parser με παράμετρο το αρχείο feed. Με αυτόν τον τρόπο γίνεται η επεξεργασία των νέων εγγραφών του access log αρχείου του apache και παραμένει ενήμερη η βάση.

5.1.1 Κώδικας του launcher.sh

```
1 #!/bin/bash
2 echo "for aetos"
3 echo "...fishing data"
4 logtail -faetos-access.log -o aetos_offset > feed
5 parser.py feed
6 echo "for www"
7 echo "...fishing data"
8 logtail -fwww-access.log -o www_offset > feed
9 parser.py feed
10 echo "JOB IS DONE!"
```

Παρατηρούμε ότι γίνεται η ίδια διαδικασία δύο φορές. Μία φορά για το αρχείο aetos-access.log και μία φορά για το αρχείο www-access.log. Ο λόγος είναι ότι στην περίπτωση του aetos ο web server ακούει σε δύο domain names και έτσι ο apache κρατάει στοιχεία σε δύο διαφορετικά αρχεία, ένα για κάθε όνομα.

5.2 PARSER.PY

Ο parser είναι ένα python script όπου παίρνει ως παράμετρο ένα αρχείο με apache access logs σε common ή σε combined μορφή. Η λειτουργία του δεν είναι άλλη από το να διαβάζει τα logs,

να ενημερώνει την βάση και στη συνέχεια να καθαρίζει τους πίνακες από τις παλιές εγγραφές.

Αρχικά θα γίνει αναφορά στις συναρτήσεις του parser, τις παραμέτρους τους και το τι επιστρέφουν.

- `month_to_num` : Διαβάζει ένα string το οποίο είναι οι τρεις πρώτοι χαρακτήρες ενός μήνα, με την μορφή που εμφανίζονται στα logs και επιστρέφει τον αριθμό που τον αντιπροσωπεύει. πχ `month_to_num('Dec')` returns 12.

```

1 def month_to_num(x):
2     months = {
3         'Jan' : 1,
4         'Feb' : 2,
5         'Mar' : 3,
6         'Apr' : 4,
7         'May' : 5,
8         'Jun' : 6,
9         'Jul' : 7,
10        'Aug' : 8,
11        'Sep' : 9,
12        'Oct' : 10,
13        'Nov' : 11,
14        'Dec' : 12
15    }
16    return months[x];

```

- `parseDates` : Αυτή η συνάρτηση παίρνει σαν παράμετρο ένα access log του apache και επιστρέφει την ημερομηνία και την ώρα τις επίσκεψης αναλυτικά.

```

1 def parseDates(x):
2     date = x[ (x.find(',')+1) : (x.find(',')+12) ];
3     year = int(x[ (x.find(',')+8) : (x.find(':')) ]);
4     month = month_to_num(x[ (x.find(',')+4) : (x.find(',')+7) ]);
5     hour = x[ (x.find(':')+1) : (x.find(':')+9) ];
6     date_hour = date+' '+hour;
7     hour = int(hour[0:2]);
8     ret = (date, year, month, hour, date_hour);
9     return ret;

```

- `getUname` : Οι παράμετροι αυτής της συνάρτησης είναι ένα `log` και ένας `integer` που αντιπροσωπεύει την θέση του `http code` στο `log`. Αυτός ο αριθμός χρειάζεται για να μην παίρνεται υπόψη ο `home` χαρακτήρας που ενδεχωμένος να προέρχεται από το πεδίο του `referer`. Η συνάρτηση επιστρέφει το όνομα του λογαριασμού του `server` στου οποίου την ιστοσελίδα έγινε η επίσκεψη.

```

1 def getUname(x, http_code_pos):
2     home_char_pos = x.find('~');
3     if home_char_pos == -1 or home_char_pos > http_code_pos:
4         //apodosi timis gia tin kentriki selida
5         usr = ':main';
6     else:
7         usr = x[ (x.find('~') + 1) : ];
8         usr = usr[ 0 : usr.find('/') ];
9         if usr.find('_') != -1:
10             usr=usr[0 : usr.find('_')];
11
11     return usr;

```

- `getDir` : Αυτή η συνάρτηση παίρνει σαν παράμετρο ένα `username` και επιστρέφει το `home directory` του.

```

1 def getDir(usr):
2     if usr == ':main':
3         directory = '/var/www';
4     else:
5         directory = pwd.getpwnam(usr).pw_dir;
6     return directory;

```

- `getGroup` : Εδώ η παράμετρος είναι το `home directory` ενός `account` και επιστρέφει το `group` που ανήκει ο χρήστης.

```

1 def getGroup(directory):
2     if directory.find('staff') != -1:
3         group = 'staff';
4     elif directory.find('student') != -1:
5         group = 'student';
6     else:
7         group = 'other';
8     return group;

```

- `getData` : Η παράμετρος είναι ένα log και επιστρέφει τον αριθμό των δεδομένων τα οποία μεταφέρθηκαν από αυτήν την αίτηση της επίσκεψης.

```

1 def getData(x):
2     r = re.compile('_[2-5][0-9][0-9]_');
3     http_code = r.search(x).group();
4     http_code_pos = x.find(http_code);
5     if http_code == '_200_':
6         data = x[x.find(http_code)+5 : ];
7         try:
8             data = int(data[0 : data.find('_')]);
9         except:
10            data = 0;
11        else:
12            data = 0;
13        if data != 0:
14            data = data / 1024.0;
15        http_code = int(http_code.strip());
16        ret = (data,http_code,http_code_pos);
17        return ret;

```

- `checkSpam` : Η συγκεκριμένη συνάρτηση παίρνει σαν παράμετρο ένα access log και ένα πίνακα που περιέχει regular expressions για spiders και robots μηχανών αναζήτησης. Στη συνέχεια ελέγχεται το log εάν προέρχεται από κάποιο robot και άν ναι απορρίπτεται.

```

1 def checkSpam(x, black_list):
2     check = False;
3     for i in black_list:
4         r=re.compile(i);
5         try:
6             tmp = r.search(x).group();
7         except:
8             tmp = -1;
9         if tmp != -1:
10            check = True;
11    return check;

```

Αφού ξεκινήσει η εκτέλεση του parser, φορτώνονται τα πακέτα sys, re και pwd από την standard βιβλιοθήκη της python. Το πακέτο sys το χρησιμοποιούμε για να μπορεί το πρόγραμμα να παίρνει σαν παράμετρο το αρχείο που πρόκειται να επεξεργαστεί από την κονσόλα. Με το

πακέτο re έχουμε την δυνατότητα να κάνουμε match τα logs με κάποια patterns που έχουν δημιουργηθεί με τη χρήση των regular expressions. Το πακέτο pwd μας παρέχει πληροφορίες για ένα λογαριασμό, όπως το login name, έτσι δίνεται η δυνατότητα ανάκτησης του home directory και άλλων χρήσιμων πληροφοριών για ένα λογαριασμό.

Εκτός των παραπάνω φορτώνεται και το πακέτο pyPgsql που δεν ανήκει στην standard βιβλιοθήκη της python και ότι πρέπει να έχει εγκατασταθεί στο σύστημα. Αυτό το πακέτο δημιουργεί μια γέφυρα επικοινωνίας μεταξύ της python και της PostgerSql, έτσι επιτυγχάνεται η ενημέρωση της βάσης μέσα από τον python κώδικα.

Αφού γίνουν τα imports ο parser εκτελεί κάποιες περαιτέρω λειτουργίες, αυτές είναι η σύνδεση στην βάση και η φόρτωση του αρχείου που περιέχει τα logs. Αυτό το αρχείο δίνεται ως παράμετρος από την κονσόλα όταν εκτελείται ο parser. Εν συνεχεία φορτώνονται στην μνήμη τα στοιχεία των λογαριασμών από τον πίνακα usrdir της βάσης.

- Ο κώδικας για την σύνδεση στην βάση :

```

1 con = PgSQL.connect(
2     database=dbname ,
3     user=dbuser ,
4     password=dbpasswd
5 );

```

- Ο κώδικας για να διαβαστούν οι λογαριασμοί των χρηστών από την βάση :

```

1 cur = con.cursor();
2 cur.execute("SELECT id, uname, directory, ugroup
3             FROM usrdir;"
4 );
5 res = cur.fetchone();

```

Έχοντας εκτελέσει όλες τις απαραίτητες προεργασίες ο parser ξεκινάει μία επανάληψη εώς ότου διαβάσει όλα τα logs του αρχείου. Αυτή η επεξεργασία γίνεται εμφωλευμένη σε ένα try για θέματα ασφάλειας. Αν κάποιο log δεν ταιριάζει σε κάποιο pattern να μην σταματήσει η λειτουργία του προγράμματος και να συνεχιστεί εώς ότου σαρωθούν όλες οι εγγραφές του αρχείου. Σε αυτήν τη επεξεργασία εξετάζονται τα logs και χρησιμοποιώντας τις συναρτήσεις που αναφέρθηκαν παραπάνω αποκτούνται όλες οι πληροφορίες που θα χρειάζονται για την δημιουργία dictionaries, μίας δομής δεδομένων της python, που αντιστοιχούν σε εγγραφές των πινάκων της βάσης.

Για την εγγραφή στη βάση μιας επίσκεψης, αυτή θα πρέπει να έχει ολοκληρωθεί επιτυχώς, αυτό εξετάζεται από τον http κωδικό που υπάρχει σε κάθε log. Αν η επίσκεψη είναι επιτυχημένη τότε ο κωδικός θα ισούται με 200. Πέραν της εξέτασης του http κωδικού εξετάζεται και αν η επίσκεψη προέρχεται από κάποιο robot ή spider. Στη συνέχεια τα dictionaries προσάπτονται

σε λίστες που αυτές αντιστοιχούν σε πίνακες της βάσης. Δηλαδή υπάρχει μία λίστα για κάθε πίνακα που περιέχει dictionaries αντί για εγγραφές. Ουσιαστικά κρατάμε αυτά τα νέα στοιχεία στην μνήμη για να αποφύγουμε άσκοπες αναφορές στη βάση που έχουν μεγάλο I/O κόστος. Μέτα την ολοκλήρωση του parsing πραγματοποιείται η ενημέρωση της βάσης, έτσι γίνονται μόνο οι απαραίτητες εγγραφές και ενημερώσεις σε αυτήν.

Οι λίστες της python έχουν ελάχιστα κοινά με την γνωστή δομή δεδομένων. Ουσιαστικά είναι πίνακες μεταβλητού μεγέθους. Η δομή dictionary της python από την άλλη είναι ένας πίνακας που οι δείκτες του αντί για αριθμοί είναι strings.

Πρέπει να αναφερθεί πως όταν γίνεται μία επίσκεψη σε μία ιστοσελίδα παρατηρούνται πολλά διαδεχόμενα logs από τον ίδιο επισκέπτη, αυτό συμβαίνει γιατί γίνονται εγγραφές και για τα αρχεία που χρησιμοποιούνται από μια ιστοσελίδα όπως φωτογραφίες ή ένα css αρχείο. Για την αποφυγεί του να υπολογίζονται σαν επισκέψεις όλα όσα κατεβαίνουν για να εμφανίστει μια ιστοσελίδα σε ένα browser, θεωρήθηκε το χρονικό διάστημα των τεσσάρων δευτερολέπτων για το οποίο τα διαδεχόμενα logs από τον ίδιο επισκέπτη προς τον ίδιο ιστότοπο δεν υπολογίζονται σαν επισκέψεις και υπόψην λαμβάνεται μόνο ο όγκος των δεδομένων.

Αφου ολοκληρωθεί η ενημέρωση της βάσης απομένει μια τελευταία λειτουργία, αυτή της διαγραφής εγγραφών που έχουν κλείσει των κύκλο ζωής τους. Αρχικά διαγράφονται οι εγγραφές του πίνακα usrdir, δηλαδή όσοι λογαριασμοί έχουν διαγραφεί από το σύστημα ή δεν έχουν καμία αναφορά σε πίνακες με εγγραφές επισκέψεων. Έπειτα διαγράφονται οι εγγραφές από τους πίνακες των επισκέψεων οι οποίες έχουν ξεπεράσει το χρόνο ζωής τους όπως αυτοί αναφέρθηκαν σε προηγούμενη παράγραφο.

- Ο κώδικας για την εισαγώγη εγγραφής στον πίνακα hpm (επισκέψεις ανά μήνα).

```

1 cur.execute("INSERT INTO hpm (uid, year, month, hits, data, ts)
2             VALUES ('%i', '%i', '%s', '%i', '%f', '%s')"
3             % (x['usrid'], x['year'], x['month'],
4                 x['hits'], x['data'], x['ts']))
5 );
6 con.commit();

```

- Ο κώδικας για την ενημέρωση εγγραφής στον πίνακα hpm (επισκέψεις ανά μήνα).

```

1 cur.execute("UPDATE hpm
2             SET hits=hits+'%i', data=data+'%f'
3             WHERE uid='%i'
4             AND year='%i'
5             AND month='%s'
6             % (x['hits'], x['data'], x['usrid'], x['year'], x['month'])
7 );
8 con.commit();

```

- Ο κώδικας για την διαγραφή εγγραφών από την βάση.

```

1 #CLEARING TABLES
2 cur.execute("DELETE FROM usrdir
3             Where id IN(
4                 SELECT u.id
5                   FROM usrdir u
6                  WHERE u.id NOT IN(
7                      SELECT u2.id
8                        FROM usrdir u2, hpm h
9                           WHERE u2.id = h.uid
10                    )
11                )"
12 );
13 con.commit();
14 cur.execute("DELETE FROM hph
15             WHERE ts < CURRENT_TIMESTAMP - interval '24 hour'"
16 );
17 cur.execute("DELETE FROM hpdp
18             WHERE ts < CURRENT_TIMESTAMP - interval '31 day'"
19 );
20 cur.execute("DELETE FROM hpm
21             WHERE ts < CURRENT_TIMESTAMP - interval '60 month'"
22 );
23 cur.execute("DELETE FROM hhmm
24 where ts < CURRENT_TIMESTAMP - interval '12 month'"
25 );
26 con.commit();
27 #END OF CLEAR

```

5.3 WEB INTERFACE

Για τη διασύνδεση του χρήστη με την υπηρεσία δημιουργήθηκε μία ιστοσελίδα στο server. Το layout διαμορφώθηκε χρησιμοποιώντας style sheets. Για ευκολότερη περιήγηση πέραν του βασικού μενού δημιουργήθηκε ένα υπομενού το οποίο εμφανίζει περισσότερες επιλογές σχετικές με αυτό που έχει ζητηθεί. Το υπομενού και το περιεχόμενο της σελίδας εμφανίζονται σε δύο html divs τα οποία δεν έχουν σταθερές διαστάσεις αλλά μεταβάλλονται ανάλογα με το μέγεθος της πληροφορίας που εμφανίζουν, αυτό επετεύχθει με τη χρήση των CSS όπως αναφέρθηκε παραπάνω. Επιπλέον υπάρχει ένα div στο οποίο εμφανίζεται σε ποια ιστοσελίδα βρισκόμαστε.

5.3.1 Προγραμματιστικό μέρος web interface

Όσον αφορά το προγραμματιστικό μέρος της ιστοσελίδας, οι κύριες απαιτήσεις ήταν η σύνδεση με την βάση, η εκτέλεση των κατάλληλων sql queries και τέλος η εμφάνιση των αποτελεσμάτων. Τα δύο πρώτα υλοποιήθηκαν με την χρήση της PHP, για την σύνδεση αυτής με την PostgreSQL χρησιμοποιήθηκε το interface php-postgres. Για την εμφάνιση των αποτελεσμάτων χρησιμοποιήθηκε το Smarty, μια μηχανή που παράγει templates για PHP. Με αυτόν τον τρόπο διαχωρίσθηκε το λειτουργικό μέρος από αυτό της εμφάνισης και έτσι ο PHP κώδικας δεν μπλέχτηκε με HTML tags. Όταν καλείται ένα php, αφού εκτελεστεί διοχετεύει τα αποτελέσματα στο Smarty, κατόπιν εμφανίζονται διαμορφωμένα από τα templates που έχουν ορισθεί.

Αναλυτικότερα, καλώντας ένα php αρχείο, αρχικοποιούνται οι μεταβλητές του από τα links χρησιμοποιώντας την http μέθοδο GET. Έπειτα εκτελείται το αρχείο το οποίο συνδέεται στην βάση, στη συνέχεια εξετάζονται οι τιμές των παραμέτρων και διαμορφώνεται το κατάλληλο query το οποίο εκτελείται από το DBMS. Κατόπιν η βάση επιστρέφει τα αποτελέσματα τα οποία διοχετεύονται στο Smarty για να εμφανιστούν διαμορφωμένα από τα templates που έχουν ορισθεί.

- Η εντολή για την σύνδεση στην βάση :

```

1 $dbccon = pg_connect("dbname=$dbname
2                         user=$dbusr
3                         password=$passwd")
4 or die('Could not connect: ' . pg_last_error());
```

- Η εντολή για την εκτέλεση ενός query :

```

1 $result=pg_query($query)
2 or die('Query failed: ' . pg_last_error());
3 $arr1=pg_fetch_all($result);
4 pg_free_result($result); //Free resultset
```

Το λειτουργικό μέρος αποτελείται από πέντε php αρχεία, τα οποία αναφέρονται παρακάτω.

- stats.php : Εμφανίζει στοιχεία σχετικά με την κίνηση της ημέρας όπως των αριθμό των επισκέψεων, των όγκο δεδομένων που κατέβηκαν και μεγέθη σχετικά με την κατανομή των επισκέψεων ανά ομάδα ιστότοπων.
- showdata.php : Αναζητά ένα λογαριασμό στη βάση, εμφανίζει τις συνολικές επισκέψεις και τον συνολικό όγκο που κατέβηκε από ένα λογαριασμού ή μια ομάδα ή για όλο τον server. Επίσης εμφανίζει στοιχεία για την κίνηση σε έναν ιστόστοπο για τα χρονικά διαστήματα της τρέχουσας ώρας, μέρα, μήνα, τους τελευταίους τρείς και έξι μήνες, το τρέχων έτος και τα τελευταία δύο έτη.

- mostvisited.php : Εμφανίζει τους ιστότοπους με την μεγαλύτερη επισκεψιμότητα στο σύνολο του server αλλά και για κάθε κατηγορία ξεχωριστά. Υπάρχει η δυνατότητα να αναζητήσετε τη όλη ενός λογαριασμού σε αυτή τη λίστα ή ακόμα και να κινηθείτε σε αυτήν με την χρήση βέλων.
- topmonths.php : Εμφανίζει τους μήνες με τις περισσότερες επισκέψεις για κάποιον ιστότοπο και για κάθε κατηγορίας.
- graphs.php : Δημιουργεί γραφήματα για την παρουσίαση τις επισκεψιμότητας ενός ιστότοπου για συγκεκριμένα χρονικά διαστήματα και υπολογίζει τον μέσο όρο των επισκέψεων για αυτά. Επισης για την κατανομή των επισκέψεων ανα κατηγορία αλλά και για την παρουσίαση της κατανομής των επισκέψεων στην διάρκεια της μέρας.

Για κάθε ένα από τα παραπάνω αρχεία υπάρχει και το αντίστοιχο template για την μορφοποίηση της εμφάνισης των αποτελεσμάτων τους.

Στο αρχείο graphs.php χρησιμοποιείται η βιβλιοθήκη Graphprite για την δημιουργία των γραφημάτων. Με την βοήθεια αυτής της βιβλιοθήκης δημιουργούνται γραφήματα τύπου γραμμής για την εμφάνιση της κατανομής των επισκέψεων ανά ώρα. Όσον αφορά την αναπαράσταση τις κίνησης των τελευταίων εώς και εικοσιτεσσάριων ωρών, τριανταενός ημερών, των τελευταίων μηνών και χρόνων παρουσιάζονται με γραφήματα τύπου στήλης. Για την εμφάνιση της κατανομής των επισκέψεων στον webserver ανά κατηγορία χρησιμοποιούνται γράφηματα τύπου πίτας και για αναλυτική παρουσίαση αυτής της κατανομής για συγκεκριμένα χρονικά διαστήματα χρησιμοποιούνται γραφήματα τύπου σωρευμένων στηλών.

- Τα χρονικά αυτά διαστήματα είναι :
 - Τον τρέχων μήνα
 - Τους τελευταίους τρείς μήνες
 - Τους τελευταίους έξι μήνες
 - Το τρέχων έτος
 - Τα τελευταία δύο έτη
 - Συνολικά

Η βιβλιοθήκη Graphprite είναι γραμμένη σε PHP και είναι ανοιχτού κώδικα. Η εξέλιξη της βιβλιοθήκης γίνεται πλέον από την PEAR με το όνομα Image_Graph. Η μόνη απαίτηση για τη λειτουργία της είναι η βιβλιοθήκη GD, για καλύτερα αποτελέσματα συνιστάται η δεύτερη έκδοσης της, GD 2. Για να μην επιβαρυνθεί το σύστημα, τα αρχεία της βιβλιοθήκης προστέθηκαν στον κατάλογο της ιστοσελίδας της υπηρεσίας και φορτώνονται μόνο κατά την εκτέλεση του graphs.php.

Το αρχείο Graph πέραν της δημιουργίας γραφημάτων για την αναλυτική εμφάνιση των επισκέψεις για ένα χρονικό διάστημα, υπολογίζει και εμφανίζει και τον μέσο όρο επισκέψεων για αυτό το διάστημα και τον όγκο δεδομένων που κατέβηκαν από την ιστοσελίδα.

Το web interface της υπηρεσίας υπολογίζει και παρουσιάζει τους ιστότοπους με την μεγαλύτερη επισκεψιμότητα στο server και σε κάθε κατηγορία ξεχωριστά. Αρχικά εμφανίζει τους πρώτους δέκα όμως υπάρχει η δυνατότητα να κινηθείτε σε αυτήν την λίστα. Με τη χρήση δύο βέλων μπορείτε να εμφανίσετε τους επόμενους ή τους προηγούμενους ιστότοπους της κατάταξης. Επίσης μπορείτε να αναζητήσετε την θέση ενός ιστότοπου σε αυτή την λίστα, είτε στην κατάταξη για όλο το server, είτε ειδικά για κάποια κατηγορία.

Με μία περιήγηση στην ιστοσελίδα της υπηρεσίας μπορείτε να πληροφορηθείτε αναλυτικά για τις επισκέψεις που έχουν πραγματοποιηθεί καθώς και για το μέγεθος των δεδομένων που μεταφέρθει και αναλυτικά για το πότε έγιναν. Ακόμα μπορείτε να ενημερωθείτε για την κατανομή των επισκέψεων ανά ώρα αλλά και ανά κατηγορία. Οι παραπάνω πληροφορίες είναι διαθέσιμες για κάθε ιστότοπο, για κάθε κατηγορία και για το σύνολο του webserver.

5.3.2 Γραφήματα του graphs.php

Η παρακάτω εικόνες είναι γραφήματα που παράγονται δυναμικά από το αρχείο graphs.php χρησιμοποιώντας την βιβλιοθήκη Graphite.

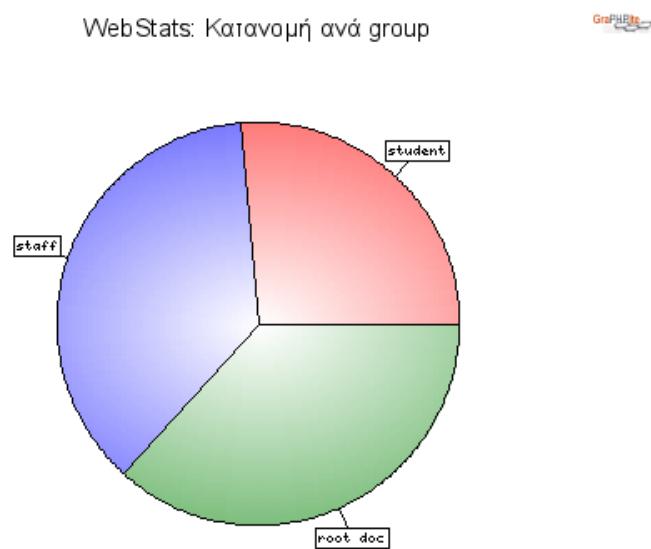


Figure 5.1: Η κατανομή των επισκέψεων ανά κατηγορία συνολικά

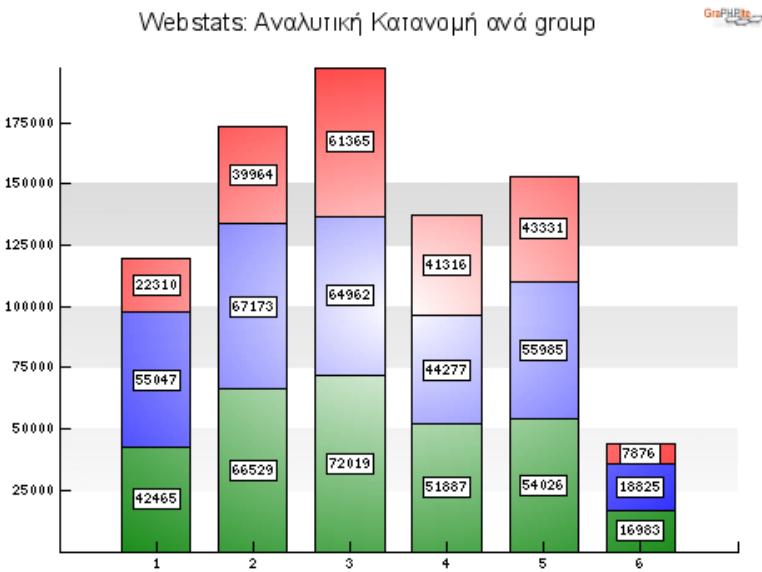


Figure 5.2: Η κατανομή των επισκέψεων ανά κατηγορία τους τελευταίους μήνες

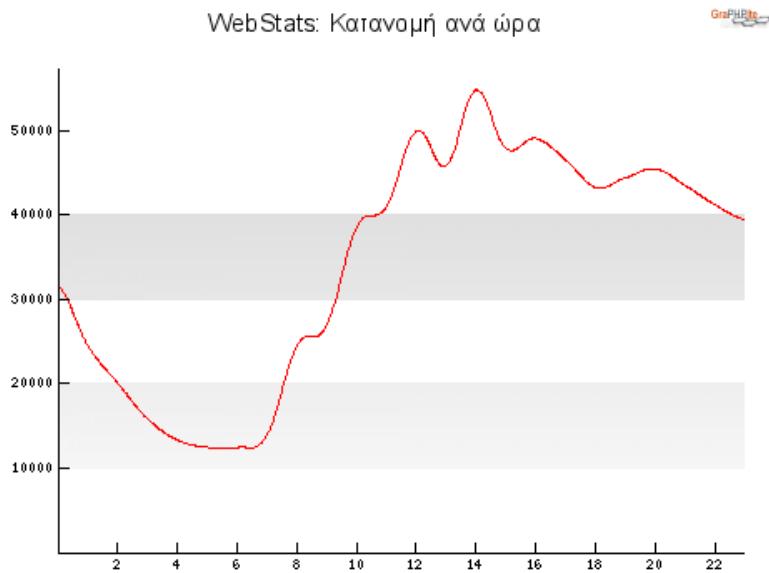


Figure 5.3: Η κατανομή των επισκέψεων ανά ώρα

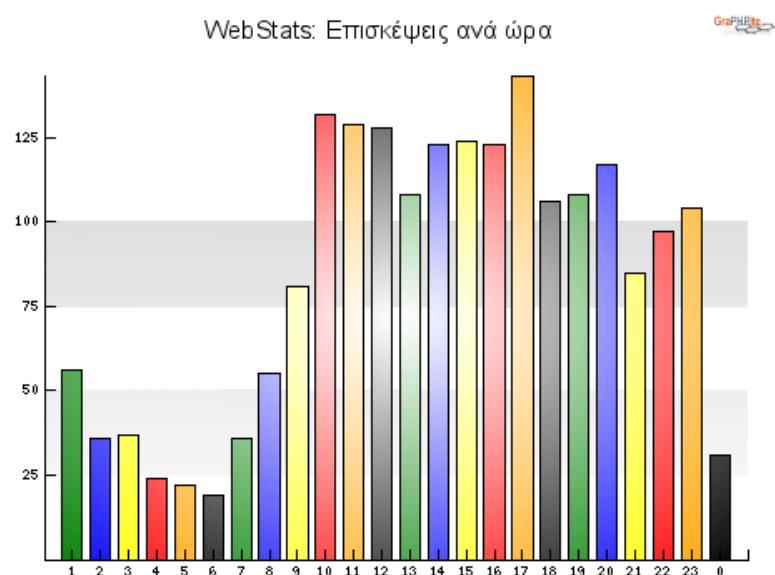


Figure 5.4: Γραφήμα στήλης για τις επισκέψεις των τελευταίων 24 ωρών

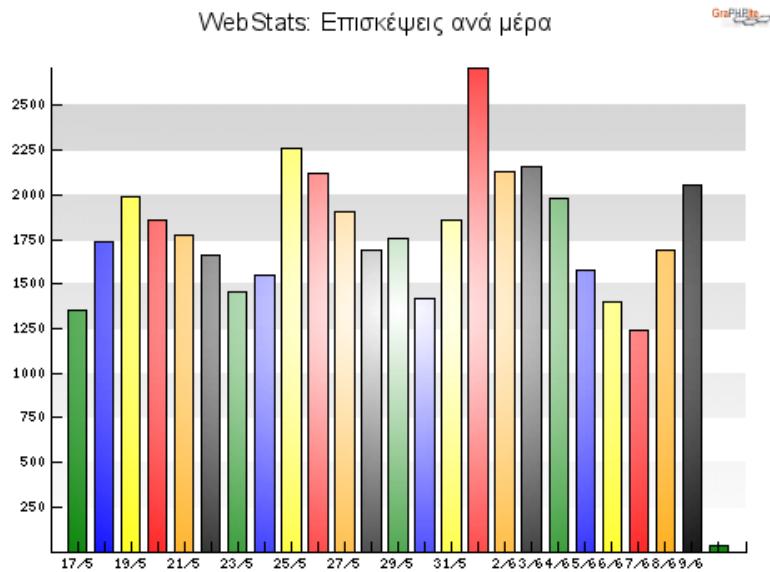


Figure 5.5: Γραφήμα στήλης για τις επισκέψεις των τελευταίων ημερών

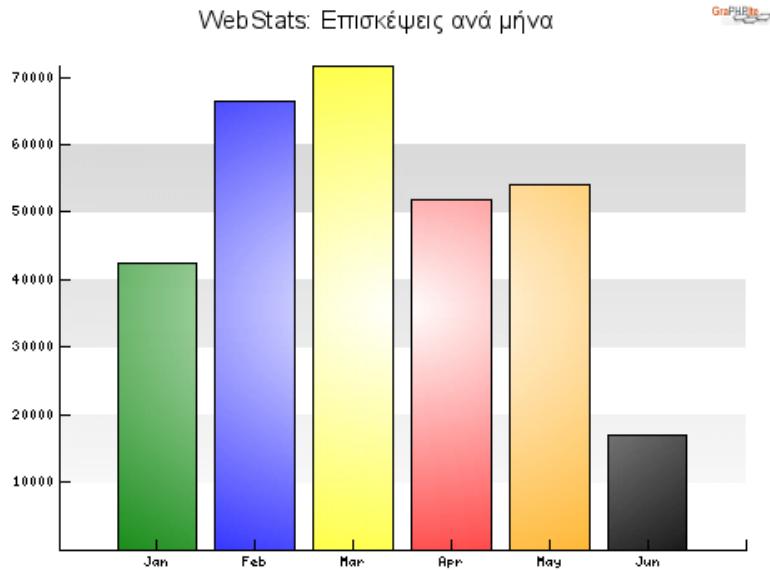


Figure 5.6: Γραφήμα στήλης για τις επισκέψεις των τελευταίων μηνών

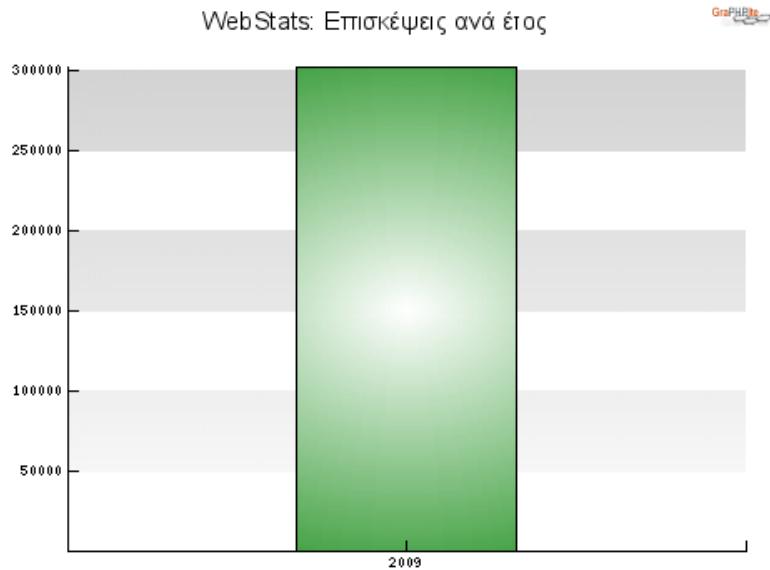


Figure 5.7: Γραφήμα στήλης για τις επισκέψεις ανά έτος

5.3.3 Counter

Το εργαλείο webstats προσφέρει την δυνατότητα στους χρήστες του aetos, τοποθέτησης counter στις ιστοσελίδες τους. Το αρχείο counter.php παίρνοντας σαν παράμετρο το όνομα ενός λογαριασμού υπολογίζει των αριθμό των συνολικών επισκέψεων και όγκου δεδομένων, που έχουν κατέβει και με τη χρήση της βιβλιοθήκης GD2 τα εμφανίζει σε μία εικόνα. Εκτός των συνολικών επισκέψεων και δεδομένων εμφανίζει και από ποια ημερομηνία και έπειτα έχουν πραγματοποιηθεί αυτά τα στοιχεία. Η εικόνα που παράγεται είναι αρχείο τύπου png. Οδηγίες για την εγκατάσταση του counter δίνονται στην υποενότητα 6.2.1.

- Ο κώδικας του counter.php :

```

1 #!/usr/local/bin/php
2 <?php
3 function getcount($uname) {
4     //connect

```

```

5      $dbcon = pg_connect("dbname=$dbname user=$dbusr password=
6          $passwd")
7      or die('Could not connect: ' . pg_last_error());
8
9      $result=pg_query("SELECT sum(h.hits) AS hits, sum(h.data)
10         AS data FROM hpm h, usrdir u WHERE u.id=h.uid AND u.
11         uname='\$uname'")
12     or die('Query failed: ' . pg_last_error());
13     $hits = pg_fetch_result($result,0,0);
14     $data = pg_fetch_result($result,0,1);
15     //Free resultset
16     pg_free_result($result);
17
18     $result=pg_query("SELECT date_part('day',h.ts),date_part('
19         month',h.ts),date_part('year',h.ts) FROM hpm h, usrdir u
20         WHERE u.id=h.uid and u.uname='\$uname' ORDER BY h.ts ASC
21         LIMIT 1")
22     or die('Query failed: ' . pg_last_error());
23     $day = pg_fetch_result($result,0,0);
24     $month = pg_fetch_result($result,0,1);
25     $year = pg_fetch_result($result,0,2);
26     //Free resultset
27     pg_free_result($result);
28     $since_date = "$day-$month-$year";
29
30     $counter = array(1 => $hits, 2 => $data, 3 => $since_date);
31     return $counter;
32 } //eof getcount
33
34 $username = $_GET['username']; //onoma logariasmou
35 $counter = getcount($username);
36 $hits = $counter[1];
37 $data = $counter[2];
38 $since_date = $counter[3];
39 $title = " webstats: $username ";
40 $bottomline = " since $since_date ";
41 $font = 5;
42 $font2 = 3;
43 $stringhits = " $hits hits ";
44
45 if($data > 1024 ) {
46     $stringdata = " $data data ";
47 }
```

```
40     $data = $data/1024;
41     $data = round($data,2);
42     $stringdata = " $data MB ";
43 else {
44     $stringdata = " $data KB ";
45
46 if(strlen($stringhits) > strlen($stringdata) and strlen(
47     $stringhits) > strlen($title) and strlen($stringhits) >
48     strlen($bottomline) ) {
49     $width = ImageFontWidth($font) * strlen($stringhits); }
50 elseif (strlen($stringdata) > strlen($title) and strlen(
51     $stringdata) > strlen($bottomline) ) {
52     $width = ImageFontWidth($font) * strlen($stringdata); }
53 else {
54     if(strlen($bottomline) > strlen($title) ) {
55         $width = ImageFontWidth($font2) * strlen($bottomline);
56         }
57     else {
58         $width = ImageFontWidth($font2) * strlen($title); }
59 }
60
61 $height = ImageFontHeight($font) + ImageFontHeight($font2) +
62     10;
63 $im = imagecreatetruecolor($width+4, $height+21);
64 $white = imagecolorallocate($im, 255, 255, 255);
65 $black = imagecolorallocate($im, 0, 0,0);
66 imagefilledrectangle($im, 3, 14, $width, $height+8, $white);
67 imagestring ($im, $font2, 4, 1, $title, $white);
68 imagestring ($im, $font, 4, 15, $stringhits, $black);
69 imagestring ($im, $font, 4, $height/2+11, $stringdata, $black)
70 ;
71 imagestring ($im, $font2, 4, $height+8, $bottomline, $white);
72 header ("Content-type: image/png");
73 imagepng ($im);
74 imagedestroy ($im);
75 ?>
```


6 ΕΓΚΑΤΑΣΤΑΣΗ

6.1 ΑΠΑΙΤΗΣΕΙΣ ΣΥΣΤΗΜΑΤΟΣ

1. Logtail
2. Apache Web Server, όπου τα access logs θα είναι σε common ή combined μορφή
3. Python 2.x
4. pyPgSQL
5. PostgreSQL 7.x ή νεότερη έκδοση
6. PHP 4 ή νεότερη έκδοση
7. PHP PostgreSQL Driver
8. Η βιβλιοθήκη GD 2 της PHP
9. Smarty Template Engine

6.2 ΟΔΗΓΙΕΣ ΕΓΚΑΤΑΣΤΑΣΗΣ

Εφόσον πληρούνται όλες οι απαιτήσεις τότε απομένουν μερικά απλά βήματα ώστε η υπηρεσία webstats να τρέξει σε ένα σύστημα. Θα πρέπει να τονιστεί πως το όλο εγχείρημα είναι χτισμένο για τον server του τμήματος πληροφορικής, μόνο σε αυτόν μπορεί να λειτουργήσει. Βέβαια μετά από αρκετές μετατροπές θα ήταν δυνατό να τρέξει και σε άλλο μηχάνημα.

Η ουσιαστική αλλαγή που θα πρέπει να γίνει για την μεταφορά αυτής της εφαρμογής σε ένα άλλο μηχάνημα είναι ο τρόπος κατηγοριοποίησης των λογαριασμών του server. Στο server aetos οι λογαριασμοί χωρίζονται σε staff και student, δηλαδή αυτούς που ανήκουν στο προσωπικό του τμήματος όπως οι καθηγητές και αυτούς που ανήκουν σε φοιτητές. Οι μετατροπές που θα πρέπει να γίνουν είναι στην συνάρτηση getGroup του αρχείου parser.py αλλά και στο constraint που διασφαλίζει τις σωστές τιμές για το πεδίο usergroup των πίνακα usrdir της βάσης. Το αρχείο με τον sql κώδικα για την δημιουργία των πινάκων είναι το webstats_tables.sql.

Αυτό που θα πρέπει να αλλάξει στην συνάρτηση είναι η λογική με την οποία κατηγοριοποιούμε τους λογαριασμούς. Για παράδειγμα στην συνάρτηση getGroup του parser εξετάζεται το home directory ενός λογαριασμού και κατηγοριοποιείται ανάλογα. Αν το path ξεκινάει

με /home/staff το group παίρνει την τιμή staff, αν ξεκινάει με /home/student παίρνει τιμή student, αλλιώς παίρνει τιμή other. Αυτή η λογική βασίστηκε στον τρόπο που οργανώνονται οι λογαριασμοί στον server του τμήματος. Ο τρόπος οργάνωσης των λογαριασμών είναι αυτό που καθορίζει την λειτουργία της συνάρτησης getGroup.

Όπως αναφέραμε και στην προηγούμενη υποενότητα, στις απαιτήσεις του συστήματος, οι εγγραφές του apache για τα access logs θα πρέπει να είναι σε μορφή combined.

Παρακάτω αναφέρονται οι οδηγίες της εγκατάστασης βήμα προς βήμα.

1. Αντιγραφή των αρχείων launcher.sh και python.py στο σύστημα μας.
2. Επεξεργασία του αρχείου launcher.sh, δήλωση των full paths των αρχείων που καλούνται.
3. Δημιουργία των πινάκων της βάσης στην Postgresql. Οι εντολές για την δημιουργία τους βρίσκονται στο αρχείο webstats_tables.sql.
4. Επεξεργασία του αρχείου parser.py. Δήλωση των τιμών των μεταβλητών database και password, το όνομα της βάσης όπου δημιουργήθηκαν οι πίνακες και το κωδικό πρόσβασης σε αυτήν αντίστοιχα.
5. Επόμενο βήμα είναι η προσθήκη του web interface. Αντιγραφή των αρχείων στο σύστημα και δήλωση τιμών στα php αρχεία για το όνομα και το password της βάσης.
6. Δημιουργία ενός φακέλου με το όνομα smarty και 4 ακόμα υποφακέλους με τα ονόματα :
 - templates
 - templates_c
 - cache
 - configs
7. Αντιγραφή των smarty templates, τα αρχεία με κατάληξη tpl, στον φάκελο που δημιουργήθηκε πριν με όνομα templates.
8. Τέλος η δημιουργία ένα δαίμονα που θα εκτελεί κάθε 15 λεπτά το αρχείο parser.py. Στο κεφάλαιο ΧΡΗΣΗ δίνονται οδηγίες για το πως γίνεται.

Αυτό που θα πρέπει να προσεχθεί είναι τα δικαιώματα πρόσβασης που θα ορισθούν για τα αρχεία της εφαρμογής. Ειδικότερα για τα αρχεία που συνδέονται στην βάση και περιέχουν το κώδικο πρόσβασης συνιστάται η αφαίρεση του δικαιώματος ανάγνωσης και εγγραφής σε αυτά. Επίσης στα αρχεία της ιστοσελίδας της υπηρεσίας να δωθούν δικαιώματα ανάγνωσης ώστε να είναι δυνατή η εμφάνιση τους από τους web browsers.

6.2.1 Εγκατάσταση counter σε ιστοσελίδα

Για την εμφάνιση του counter σε ιστοσελίδα όταν πρέπει να δημιουργηθεί ένα image tag και στην ιδιότητα src να δωθεί η τιμή της διαδρομής του αρχείου counter.php καθώς και να δηλωθεί το όνομα του λογαριασμού του οποίου τα στοιχεία όταν εμφανισθούν. Για παράδειγμα, εάν πρόκειται να εμφανίσουμε τον αριθμό επισκέψεων του ιστότοπου του λογαριασμού αρναν όταν πρέπει προστεθεί ο παρακάτω κώδικα στην εν λόγω ιστοσελίδα.

```

```

O counter έχει τη μορφή :



Figure 6.1: counter

7 ΧΡΗΣΗ

Το webstats ξεκίνησε να συλλέγει δεδομένα για την επισκεψιμότητα στον web server του τμήματος από τις 15 Ιανουαρίου του 2009. Παρακάτω παρατίθεται ένας πίνακας με στοιχεία για την λειτουργία του εργαλείου για ένα διάστημα λίγο μεγαλύτερο των πέντε μηνών.

Όνομα Πίνακα	Αριθμός Εγγραφών
usrdir	289
hph	933
hpd	3820
hpm	1521
hhm	22099

Συνολικός Αριθμός Εγγραφών | 28662

7.1 SHELL ΕΝΤΟΛΕΣ

- Για την δημιουργία της βάσης αφού συνδεθούμε στην Postgresql, δίνεται η εντολή σε `psql` περιβάλλον.

```
CREATE DATABASE dbname OWNER username;
```

- Για την δημιουργία των πινακων δίνετε η παρακάτω εντολή το shell.

```
psql -d dbname -U username -f webstats_tables.sql
```

- Η μορφή της εντολής logtail. Το filename ειναι το αρχείο προς ανάγνωση και το offsetfile το αρχείο που έχει τις offset εγγραφές.

```
logtail -ffilename -ooffsetfile
```

- Για την εκτέλεση του parser δίνουμε σαν δεύτερη παράμετρο το αρχείο με τα logs.

```
parser.py filename
```

- Για την δημιουργία ενός δαίμονα για την εκτελεση του launcher.ssh και την σάρωση των access logs του webserver και την ενημέρωση της βάσης ανά τακτά διαστήματα όπα χρησιμοποιήθει το Cron. Ένα εργαλείο για την δήλωση προγραμματισμένων εργασιών. Η εντολή που όπα πρέπει να δωθεί είναι η παρακάτω.

```
crontab -u user -e
```

- Αφού ανοιχθεί το αρχείο με τις προγραμματισμένες εργασίες, εισάγετε την παρακάτω γραφμή και σώζετε το αρχείο. Θα πρέπει να δηλώθεί όλη η διαδρομή για την εργασία που θα εκτελείται. Η παρακάτω εγγραφή σημαίνει ότι στο 15ο, 30ο, 45ο και 59ο λεπτό για κάθε ώρα, κάθε μήνα και κάθε χρόνο θα εκτελείται το script launcher.sh, δηλαδή κάθε δεκαπέντε λεπτά. Το output της εντολής διοχετεύεται στο /dev/null ώστε να μήν αποστέλεται κάθε φορά με e-mail στον χρήστη που το εκτελεί.

```
15,30,45,59 * * * * launcher.sh > /dev/null
```

7.2 ΟΔΗΓΙΕΣ ΧΡΗΣΗΣ

Σε αυτήν την υποενότητα δίνονται οδηγίες για το πως μπορείτε να εμφανίσετε αποτελέσματα στην ιστοσελίδα. Για μεγαλύτερη κατανόηση γίνεται χρήση εικόνων.

- Για την εμφάνιση στοιχείων για το server ή για κάποια κατηγορία ή για ένα χρήστη, πρέπει να επιλεγεί από το κεντρικό μενού η “Αναζήτηση”. Στη συνέχεια ή εκτελούμε μία αναζήτηση για κάποιο χρήστη ή εμφανίζουμε μία εκ των επιλογών στο υπομενού αριστερά. Η επιλογές είναι :

1. server
2. Κεντρική Σελίδα
3. Προσωπικό
4. Φοιτητές

Εμφάνισε στοιχεία για : <ul style="list-style-type: none"> όλο το server την κεντρική σελίδα to group: staff to group: student 	Αναζήτηση Παρακαλώ εισάγετε το όνομα του λογαριασμού. username: <input type="text" value="arnav"/> <input type="button" value="submit"/>
---	---

Figure 7.1: Αναζήτηση

- Η παρακάτω εικόνα είναι η εμφάνιση στοιχείων για την κεντρική σελίδα. Επιπλέον μπορούμε να εμφανίσουμε την κατανομή ανά ώρα ή τις περιόδους με τις περισσότερες επισκέψεις για αυτήν την σελίδα από το υπομενού αριστερά. Επίσης στο κάτω μέρος της σελίδας βρίσκονται links για την εμφάνιση γραφημάτων για αναλυτική παρουσίαση της επισκεψιμότητας.

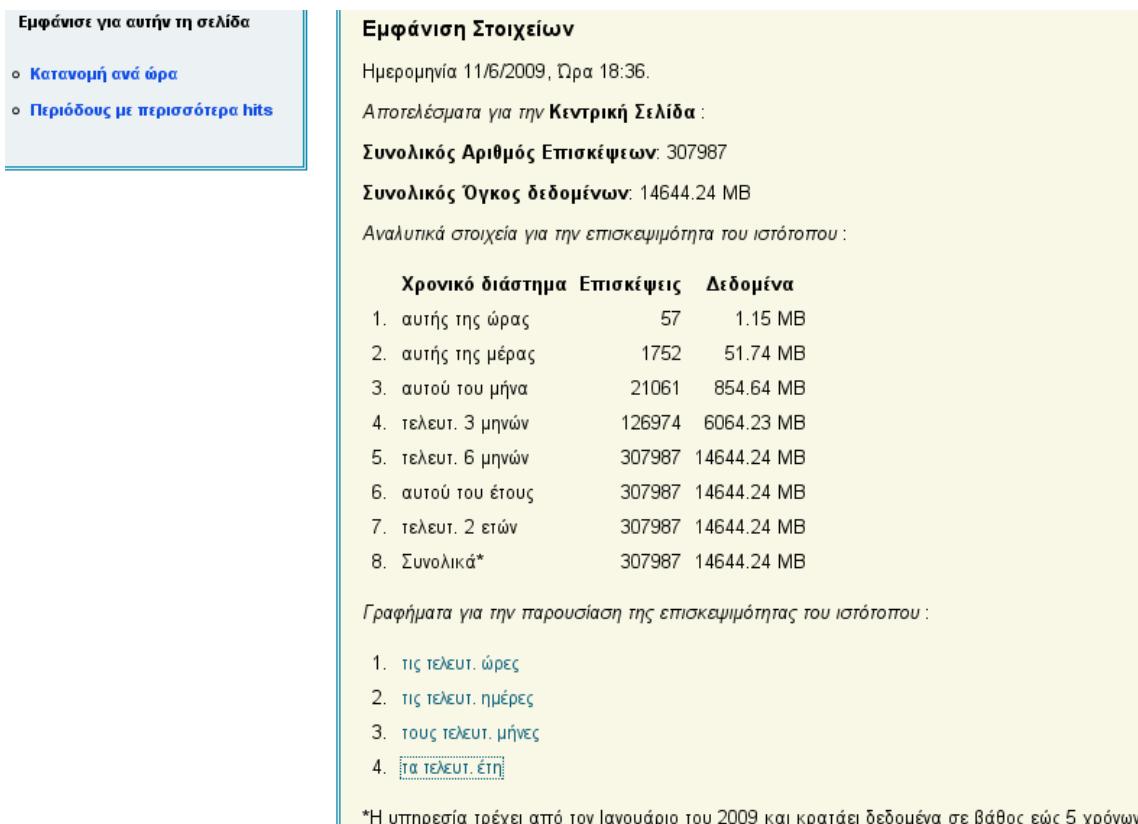


Figure 7.2: Εμφάνιση Στοιχείων

- Έχοντας εμφανίσει το γράφημα για την αναπαράσταση της κίνησης για ένα από τα χρονικά διαστήματα που έχουν αναφερθεί, υπάρχει η δυνατότητα εμφάνισης των υπολοίπων από το υπομενού αριστερά. Όσον αφορά το διάστημα των τελευταίων ετών υπάρχουν κάποιες περαιτέρω επιλογές που αφορούν την αναλυτική παρουσίαση της κίνησης για κάθε έτος ειδικά. Στην εικόνα που ακολουθεί εμφανίζεται η κίνηση των τελευταίων μηνών :

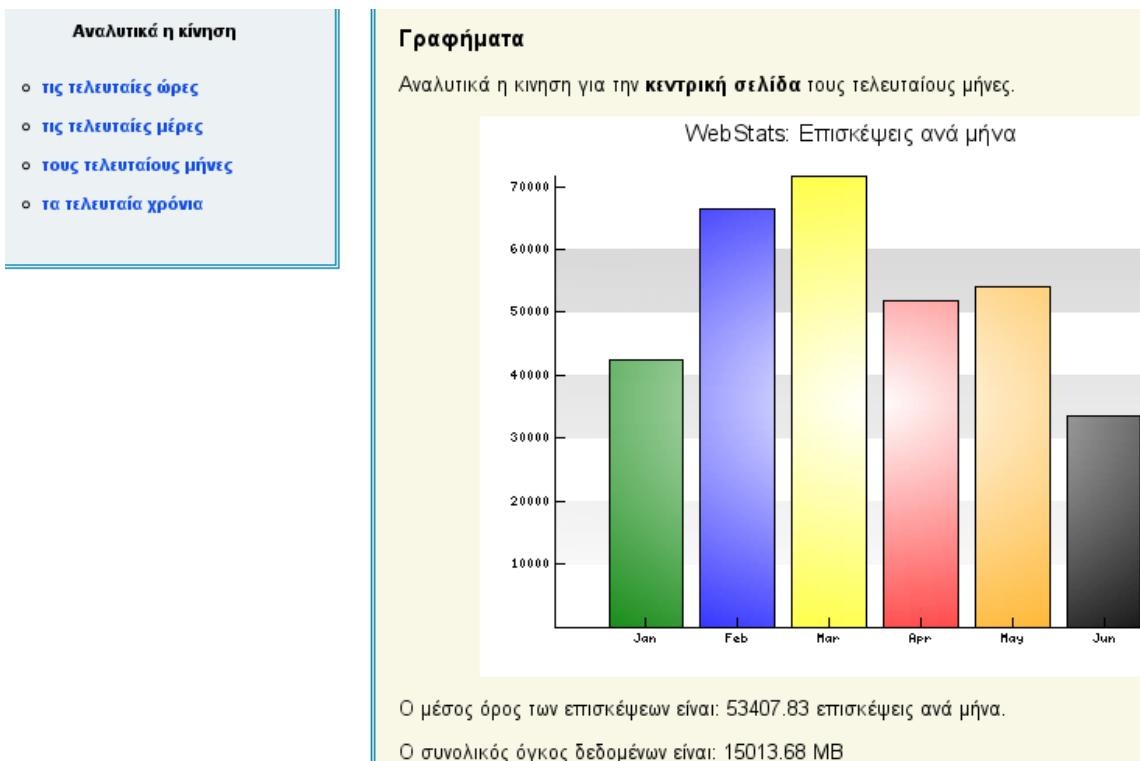


Figure 7.3: Γράφημα αριθμ. επισκέψεων των τελευταίους μηνών

- Αν επιλέξουμε “Κατανομή ανά ώρα” από το υπομενού στην σελίδα “Εμφάνιση Στοιχείων”, υπάρχει η δυνατότητα της εμφάνισης αυτής της κατανομής για περισσότερα από ένα χρονικά διαστήματα. Αυτά τα διαστήματα είναι των τελευταίων δώδεκα εώς ενός μηνών. Η επιλογή γίνεται από την λίστα στο κάτω μέρος της σελίδας. Δείτε στην εικόνα :

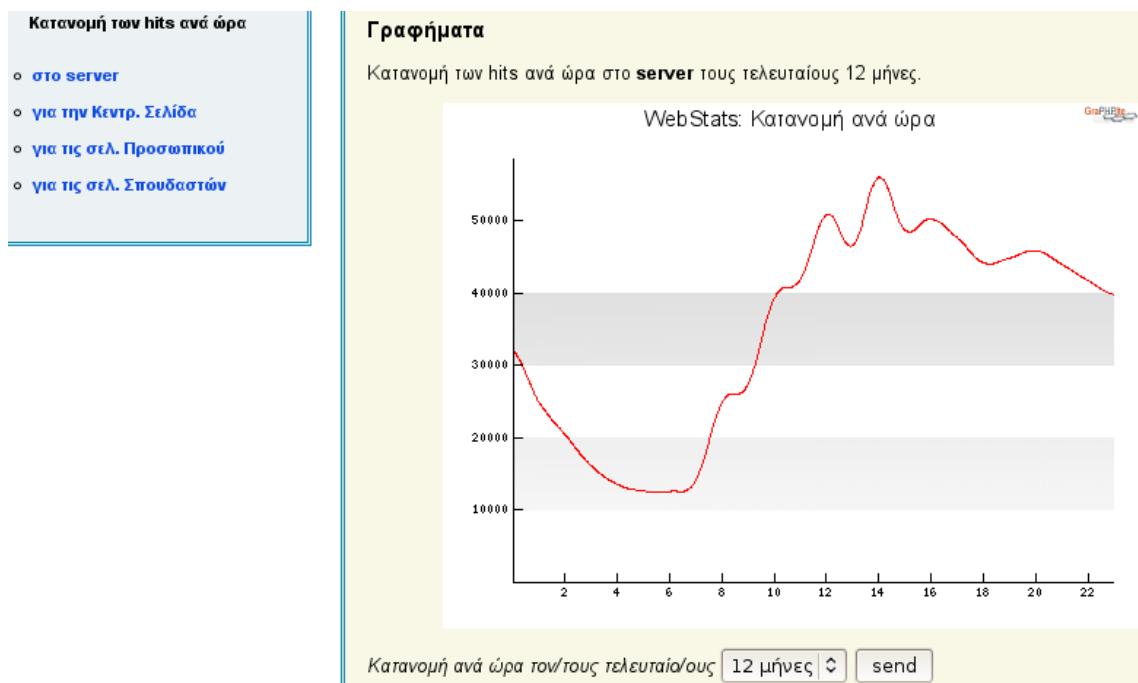


Figure 7.4: Κατανομή ανά ώρα

- Για να εμφανίσουμε τα στατιστικά της σημερινής ημέρας, επιλέγουμε “Στατιστικά” από το κεντρικό μενού. Στην σελίδα Στατιστικά, στο υπομενού αριστερά υπάρχουν οι επιλογές :

1. Δημοφιλέστερες Σελίδες
2. Περίοδοι με τα περισσότερα hits (στο server)
3. Κατανομή ανά group
4. Κατανομή ανά ώρα (στο server)



Figure 7.5: Στατιστικά

- Εάν επιλέξουμε “Δημοφιλέστερες Σελίδες” από την σελίδα “Στατιστικά”, μπορούμε να εμφανίσουμε τις δημοφιλέστερες σελίδες σε όλο τον server ή και για κάθε κατηγορία ξεχωριστά, αυτές οι επιλογές βρίσκονται στο υπομενού αριστερά. Από την φόρμα στο κάτω μέρος της σελίδας μπορούμε να αναζητήσουμε την θέση ενός χρήστη σε αυτήν την λίστα, είτε για όλο τον server, είτε για το group που ανήκει. Ακόμα υπάρχουν δύο βέλη για να εμφανίσουμε τις επόμενες και τις προηγούμενες θέσεις. Δείτε στην εικόνα :

Πιο δημοφιλείς σελίδες

- [στο server](#)
- [στις σελίδες προσωπικού](#)
- [στις σελίδες σπουδαστών](#)

Δημοφιλέστερες Σελίδες

Σελίδες με την μεγαλύτερη επισκεψιμότητα στο **server**.

	username	hits	data	group
1.	Κεντρ. ΣΕΛ.	307963	14643.55 MB	-
2.	ekprosop	86738	1619.69 MB	student
3.	kdiamond	29371	10311.72 MB	staff
4.	asidirop	28776	3239.69 MB	staff
5.	peris	26617	3042.10 MB	staff
6.	theochim	23453	2709.65 MB	staff
7.	free	23438	1815.71 MB	staff
8.	axileas	18232	4581.72 MB	staff
9.	dima	17934	2033.86 MB	staff
10.	sfetsos	15738	2614.82 MB	staff

[**<<**](#) [**>>**](#)

Αναζητήστε τη θέση ενός λογαριασμού.

username: server

Figure 7.6: Δημοφιλέστερες Σελίδες

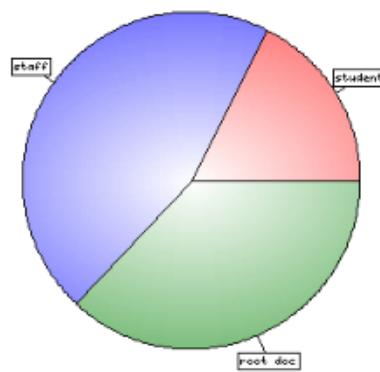
- Την κατανομή των επισκέψεων ανά group μπορούμε να την επιλέξουμε από το υπομενού της σελίδας “Στατιστικά”. Στο κάτω μέρος της σελίδας υπάρχει μια λίστα για τον υπολογισμό της κατανομής για τα εξής χρονικά διαστήματα :

 1. αυτόν το μήνα
 2. τους τελευταίους τρεις μήνες
 3. τους τελευταίους έξι μήνες
 4. αυτό το έτος
 5. τα τελευταία δύο έτη
 6. Συνολικά

Γραφήματα

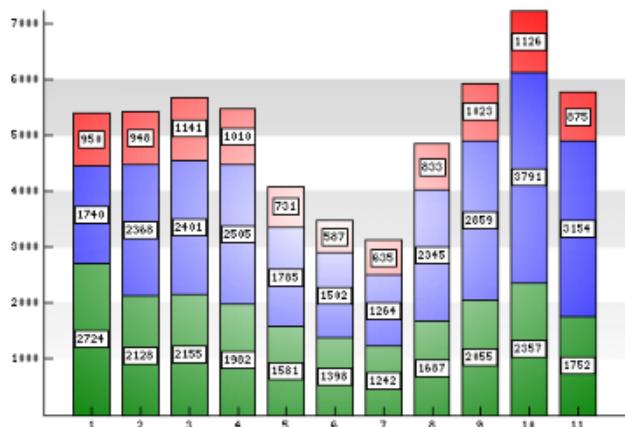
Κατανομή των επισκέψεων ανά κατηγορία για αυτόν το μήνα :

WebStats: Κατανομή ανά group



Αναλυτικά η κατανομή για αυτό το χρονικό διάστημα :

Webstats: Αναλυτική Κατανομή ανά group



Ποσοστά επί τοις εκατό για την κάθε κατηγορία :

Κεντρική Σελίδα : 37.19 %

Προσωπικό : 45.4 %

Σπουδαστές : 17.41 %

Εμφάνισε για

Figure 7.7: Κατανομή ανά group

8 ΣΧΟΛΙΑ / ΠΑΡΑΤΗΡΗΣΕΙΣ

Η υπηρεσία webstats είναι κατάλληλη για ένα webserver στον οποίο το module userdir του apache είναι ενεργοποιημένο έτσι ώστε να μπορεί ο κάθε λογαριασμός στον server να ανεβάσει την δική του ιστοσελίδα, όπως για παράδειγμα στον server aetos του τμήματος πληροφορικής. Αυτό το εργαλείο δίνει την δυνατότητα της ενημέρωσης για την επισκεψιμότητα της κάθε ιστοσελίδας, για τις κατηγορίες των φοιτητών και των καθηγητών αλλά και για όλον το server.

Για την υλοποίηση αυτής της εφαρμογής χρησιμοποιήθηκαν εργαλεία που διατίθενται ελεύθερα όπως η python για τον parser, η postgres για την βάση και η php για το web interface καθώς και κάποιες περαιτέρω βιβλιοθήκες. Η εφαρμογή αναπτύχθηκε σε περιβάλλον Unix.

Η μεταφορά του σε ένα άλλο σύστημα θα είναι δυνατή εφόσον πληρούνται όλες οι απαιτήσεις συστήματος όμως θα πρέπει να γίνουν κάποιες σημαντικές μετατροπές. Αυτές οφείλονται κυρίως στα κριτήρια με τα οποία ομαδοποιούνται οι λογαριασμοί στον εκάστοτε web server. Αυτό σημαίνει ότι θα πρέπει να γίνουν αλλαγές στο κώδικα του parser στη συνάρτηση που ομαδοποιεί τους λογαριασμούς καθώς και στο constraint του πεδίου ugroup του πίνακα usrdir που εξασφαλίζει αποδεκτές τιμές για τις εγγραφές. Ακόμα θα πρέπει να γίνουν αλλαγές στο περιεχόμενο της ιστοσελίδας και στα php αρχεία που εκτελούν ερωτήματα στη βάση.

Όσον αφορά την μεταφορά σε άλλο σύστημα όπως για παράδειγμα το Windows Server, αυτό είναι δυνατόν με κάποιες ακόμα αλλαγές. Αυτές είναι το shell script launcher.sh για την εκτέλεση του parser, η χρήση ενός προγράμματος παρόμοιου της εντολής logtail που χρησιμοποιείται για την ανάγνωση νέων εγγραφών σε κάποιο αρχείο και η χρήση ενός scheduler για προγραμματισμένες εκτελέσεις παρόμοιο με το Cron. Επίσης είναι απαραίτητες κάποιες αλλαγές στον κώδικα του parser όσον αφορά την εξόρυξη πληροφοριών για τους λογαριασμούς του συστήματος.

9 ΕΠΙΛΟΓΟΣ

Η υπηρεσία webstats μας ενημερώνει με στατιστικά στοιχεία σχετικά με την web κίνηση και είναι χτισμένο στην λογική του server του τμήματος πληροφορικής. Είναι ένα εργαλείο το οποίο δουλεύει όχι μόνο για το σύνολο ενός web server αλλά και για κάθε λογαριασμό ξεχωριστά, σε αντίθεση με τα παρόμοια υπάρχοντα εργαλεία. Η μετατροπή του για ένα άλλο μηχάνημα είναι μία απαιτητική διαδικασία και έχει αναλυθεί σε προηγούμενη παράγραφο.

Η υλοποίηση αυτής της εφαρμογής απαίτησε γνώσεις προγραμματισμού για την ανάπτυξη του parser, γνώσεις βάσεων δεδομένων για τον σχεδιασμό της βάσης και γνώσεις διαδικτυακού προγραμματισμού για την υλοποίηση του web interface. Απαραίτητες κρίθηκαν και στοιχειώδεις γνώσεις Unix συστημάτων για την εγκατάσταση και χρήση του εργαλείου.

Bibliography

- [1] Mark Lutz, O'Reilly Learning Python, 3rd Edition, *O'Reilly Media, Inc*, 2008
- [2] Raghu Ramakrishnan, Johannes Gehrke, Συστήματα Διαχείρισης Βάσεων Δεδομένων Τόμος Α, 2η Έκδοση, *Εκδόσεις Τζιολα*, 2001
- [3] Python Online Documentation, '<http://www.python.org/doc/>', *Python Software Foundation*, 2009
- [4] PostgreSql Online Documentation, '<http://www.postgresql.org/docs/>', *PostgreSQL Global Development Group*, 2008
- [5] PHP Online Documentation, '<http://www.php.net/manual/en/>', *The PHP Group*, 2009
- [6] Smarty Templates Engine Online Documentation, '<http://www.smarty.net/manual/en/>', *The PHP Group*, 2007
- [7] Graphpite Online Documentation, '<http://graphpite.sourceforge.net/docs/>', *phpDocumentor 1.2.3*, 2004
- [8] Apache Online Documentation, '<http://httpd.apache.org/docs/>', *The Apache Software Foundation*, 2009
- [9] HTML 4.01 Specification, '<http://www.w3.org/TR/REC-html40/>', *W3C*, 2009
- [10] CSS 2.1 Specification, '<http://www.w3.org/TR/CSS21/>', *W3C*, 2009
- [11] Awstats Online Documentation, '<http://awstats.sourceforge.net/docs/index.html>'
- [12] Analog Online Documentation, '<http://analog.cx/docs/Readme.html>'
- [13] Webalizer Guide, '<http://www.mrunix.net/webalizer/simpleton.html>'