

**ΤΑΥΤΟΧΡΟΝΗ ΑΝΑΓΝΩΡΙΣΗ ΤΑΞΗΣ  
ΚΑΙ ΠΑΡΑΜΕΤΡΩΝ ΜΟΝΤΕΛΩΝ  
ΧΡΟΝΟΣΕΙΡΩΝ ΜΕ ΧΡΗΣΗ  
ΠΟΛΥΜΟΝΤΕΛΙΚΟΥ ΔΙΑΜΕΛΙΣΜΟΥ**

**ΣΤΥΛΙΑΝΟΣ Σπ. ΠΑΠΠΑΣ**

**Διδακτορική Διατριβή**

Φεβρουάριος 2008



Πανεπιστήμιο Αιγαίου  
Σχολή Θετικών Επιστημών  
Τμήμα Μηχανικών Πληροφοριακών  
και Επικοινωνιακών Συστημάτων

ΤΑΥΤΟΧΡΟΝΗ ΑΝΑΓΝΩΡΙΣΗ ΤΑΞΗΣ ΚΑΙ ΠΑΡΑΜΕΤΡΩΝ  
ΜΟΝΤΕΛΩΝ ΧΡΟΝΟΣΕΙΡΩΝ ΜΕ ΧΡΗΣΗ ΠΟΛΥΜΟΝΤΕΛΙΚΟΥ  
ΔΙΑΜΕΛΙΣΜΟΥ

**ΣΤΥΛΙΑΝΟΣ Σπ. ΠΑΠΠΑΣ**

**Διατριβή**

για την απόκτηση Διδακτορικού Διπλώματος του Τμήματος Μηχανικών Πληροφοριακών και Επικοινωνιακών Συστημάτων του Πανεπιστημίου Αιγαίου

**Τριμελής Συμβουλευτική Επιτροπή**

**Ασημάκης Λερός**            Επίκουρος Καθηγητής, Πανεπιστήμιο  
Αιγαίου, Τμήμα Μηχανικών Πληροφοριακών και Επικοινωνιακών  
Συστημάτων, *Επιβλέπων*

**Σωκράτης Κάτσικας**    Καθηγητής, Πανεπιστήμιο Πειραιώς,  
Τμήμα Διδακτικής της Τεχνολογίας & Ψηφιακών Συστημάτων,  
*Μέλος* της Τριμελούς Συμβουλευτικής Επιτροπής

**Σπυρίδων Λυκοθανάσης** Καθηγητής, Πανεπιστήμιο Πατρών,  
Τμήμα Μηχανικών Η/Υ & Πληροφορικής, *Μέλος* της Τριμελούς  
Συμβουλευτικής Επιτροπής

## **Επταμελής Εξεταστική Επιτροπή**

**Ασημάκης Λερός** Επίκουρος Καθηγητής, Πανεπιστήμιο Αιγαίου, Τμήμα Μηχανικών Πληροφοριακών και Επικοινωνιακών Συστημάτων, *Επιβλέπων*

**Σωκράτης Κάτσικας** Καθηγητής, Πανεπιστήμιο Πειραιώς, Τμήμα Διδακτικής της Τεχνολογίας & Ψηφιακών Συστημάτων, *Μέλος* της Τριμελούς Συμβουλευτικής Επιτροπής

**Σπυρίδων Λυκοθανάσης** Καθηγητής, Πανεπιστήμιο Πατρών, Τμήμα Μηχανικών Η/Υ & Πληροφορικής, *Μέλος* της Τριμελούς Συμβουλευτικής Επιτροπής

**Νικήτας Νικητάκος** Καθηγητής, Πανεπιστήμιο Αιγαίου, Τμήμα Ναυτιλίας και Επιχειρηματικών Υπηρεσιών, *Μέλος*

**Δημήτριος Φωτάκης** Επίκουρος Καθηγητής, Πανεπιστήμιο Αιγαίου, Τμήμα Μηχανικών Πληροφοριακών και Επικοινωνιακών Συστημάτων, *Μέλος*

**Ηλίας Μαγκλογιάννης** Λέκτορας, Πανεπιστήμιο Αιγαίου, Τμήμα Μηχανικών Πληροφοριακών και Επικοινωνιακών Συστημάτων, *Μέλος*

**Ευστάθιος Σταματάτος** Λέκτορας, Πανεπιστήμιο Αιγαίου, Τμήμα Μηχανικών Πληροφοριακών και Επικοινωνιακών Συστημάτων, *Μέλος*

## *Δημοσιεύσεις*

*Adaptive Network Anomaly Detection using Bandwidth Utilisation Data,*

Moussas V.C, **Pappas S.S.**

1st International Conference on Experiments/Process/System Modeling/Simulation/Optimization, 1st IC-EpsMsO Athens, 6-9 July, 2005, © IC-EpsMsO

*MV AR Model Order Identification Using Partitioning Theory*

**Stylianios Sp. Pappas**, Assimakis. K. Leros, Sokratis. K. Katsikas,

12<sup>th</sup> Int. Workshop on Systems, Signals and Image Processing, 22–24 September 2005, Chalkida, Greece, Pages: 51–55.

*Multivariate AR Model Order Estimation with Unknown Process Order*

**Stylianios Sp. Pappas**, Assimakis K. Leros, Sokratis K. Katsikas

Lecture Notes in Computer Science, ISSN: 0302-9743  
Volume 3746/2005, Pages: 787–797.

*Joint order and parameter estimation of multivariate autoregressive models using multi-model partitioning theory*

**Stylianios Sp. Pappas**, Assimakis K. Leros and Sokratis K. Katsikas

Digital Signal Processing, Volume 16, Issue 6, November 2006, Pages 782-795.

*Multivariate ARMA Order Estimation Via Multimodel Partitioning Theory*

**Stylianios Sp. Pappas**, Vassilios C. Moussas, and Sokratis K. Katsikas

2<sup>nd</sup> International Conference on Experiments/Process/System Modeling/ Simulation/Optimization  
2<sup>nd</sup>, IC-EpsMsO Athens, 4-7 July, 2007, © IC-EpsMsO

*Modeling of the Grounding Resistance Variation using ARMA models*

**S.Sp. Pappas**, L. Ekonomou, P. Karampelas, S.K. Katsikas, P. Liatsis

Simulation Modelling Practice and Theory, Elsevier, In Press, Accepted Manuscript

*Application of the Multi-Model Partitioning Theory for Simultaneous Order and  
parameter Estimation of Multivariate ARMA Models*

**Stylianos Sp. Pappas**, Vassilios C. Moussas, Sokratis K. Katsikas

International Journal Of Modeling Identification and Control, Inderscience, In Press, Ac-  
cepted Manuscript

*If we knew what it was we  
were doing, it would not be  
called research, would it?*

*Albert Einstein*

## ***Ευχαριστίες - Αφιερώσεις***

**Η** εργασία αυτή εκπονήθηκε στα πλαίσια της διδακτορικής διατριβής στο Τμήμα Μηχανικών Πληροφοριακών και Επικοινωνιακών Συστημάτων της Σχολής Θετικών Επιστημών του Πανεπιστημίου Αιγαίου. Για την περαίωση της έρευνας συνέβαλαν πολλοί αξιόλογοι Άνθρωποι και Πανεπιστημιακοί Δάσκαλοι τους οποίους θα ήθελα να ευχαριστήσω.

Πρωτίστως όμως θα ήθελα να αναφέρω πως όλο το πόνημα αφιερώνεται στη μνήμη του καθηγητή Δημητρίου. Γ. Λαϊνιώτη, ο οποίος με τίμησε με την εμπιστοσύνη του, με ενθάρρυνε με το δικό του μοναδικό τρόπο, έβαλε τα θεμέλια και με στήριξε από την αρχή της προσπάθειάς μου.

Ευχαριστώ θερμά τον επιβλέποντα Καθηγητή μου κ. Σωκράτη Κάτσικα του οποίου η παρέμβαση σε όλα τα στάδια της έρευνας, η καθοδήγηση, η συμπαράσταση και η συνδρομή του για την αντιμετώπιση των δυσκολιών και των προβλημάτων ήταν ουσιαστική και πραγματικά πολύτιμη.

Επίσης θα ήθελα να ευχαριστήσω τους Επίκουρους Καθηγητές, κ. Ασημάκη Λερό για τη βοήθειά του στο ξεκίνημα της έρευνάς μου και κ. Βασίλειο Μούσσα για την ουσιαστική συμμετοχή του στην εφαρμογή του αλγορίθμου στα δίκτυα υπολογιστών.

Οφείλω ένα μεγάλο ευχαριστώ στον εξάαιρετο φίλο μου και παλιό μου δάσκαλο, Νίκο Πουρναρά, οποίος στάθηκε αφορμή να γνωρίσω όλους τους παραπάνω ανθρώπους καθώς επίσης και στον καλό μου φίλο και συνάδελφο Λάμπρο Οικονόμου για όλη του τη βοήθειά ως τώρα.

Κλείνοντας θα ήταν παράλειψη να μην εκφράσω την ευγνωμοσύνη μου στην οικογένειά μου, τους γονείς μου Σπύρο και Ελένη και τα αδέρφια μου Χρήστο και Μαρία, για την πολύπλευρη στήριξη τους, την ενθάρρυνση και την αστείρευτη αντοχή και ανοχή τους στις δικές μου ιδιοτροπίες, καθώς και στην αγαπημένη μου σύζυγο, Ανθή, για την αμέριστη συμπαράσταση και κατανόηση της καθώς και για τη μεγάλη της υπομονή και πίστη!

Στυλιανός, Σπ. Παππάς

Αθήνα, Φεβρουάριος 2008.

## ΠΙΝΑΚΑΣ ΠΕΡΙΕΧΟΜΕΝΩΝ

<b>ΕΙΣΑΓΩΓΗ</b>	<b>9</b>
Ε.1. ΤΑΥΤΟΠΟΙΗΣΗ ΣΥΣΤΗΜΑΤΟΣ ( <i>SYSTEM IDENTIFICATION</i> ).....	11
<i>E.1.1. Μη παραμετρικές μοντελικές δομές</i> .....	15
<i>E.1.2. Παραμετρικές μοντελικές δομές</i> .....	16
<i>E.1.3. Μοντελικές δομές α) με ντεντερμινιστική είσοδο, β) στοχαστική είσοδο</i> .....	17
Ε.2. ΠΕΡΙΛΗΨΗ ΔΙΑΤΡΙΒΗΣ .....	18
Ε.3. SUMMARY OF THESIS .....	20
<b>ΚΕΦΑΛΑΙΟ 1</b>	<b>24</b>
ΠΑΡΑΛΛΗΛΗ ΑΝΑΓΝΩΡΙΣΗ ΤΩΝ ΤΕΛΕΣΤΩΝ ΚΑΙ ΤΗΣ ΤΑΞΗΣ ΠΟΛΥ-ΜΕΤΑΒΛΗΤΩΝ ΑΚΟΛΟΥΘΙΑΚΩΝ ΜΟΝΤΕΛΩΝ. ....	24
1.1. ΕΙΣΑΓΩΓΗ.....	25
1.2. ΕΠΑΝΑΔΙΑΤΥΠΩΣΗ ΤΟΥ ΠΡΟΒΛΗΜΑΤΟΣ .....	28
1.3. ΠΑΡΟΥΣΙΑΣΗ ΤΩΝ ΣΥΓΚΡΙΝΟΜΕΝΩΝ ΚΡΙΤΗΡΙΩΝ. ....	35
1.4. ΠΑΡΑΔΕΙΓΜΑΤΑ ΚΑΙ ΑΠΟΤΕΛΕΣΜΑΤΑ.....	37
1.5. ΣΥΜΠΕΡΑΣΜΑΤΑ .....	46
<b>ΚΕΦΑΛΑΙΟ 2</b>	<b>49</b>
ΠΡΟΣΑΡΜΟΖΟΜΕΝΗ ΑΝΙΧΝΕΥΣΗ ΔΙΚΤΥΑΚΩΝ ΔΙΑΤΑΡΑΧΩΝ ΜΕ ΤΗ ΧΡΗΣΗ ΔΕΔΟΜΕΝΩΝ ΕΚΜΕΤΑΛΛΕΥΣΗΣ ΕΥΡΟΥΣ ΖΩΝΗΣ.....	49
2.1. ΕΙΣΑΓΩΓΗ.....	50
2.2. ΜΟΝΤΕΛΟΠΟΙΗΣΗ ΤΗΣ ΚΙΝΗΣΗΣ ΔΙΚΤΥΟΥ ΜΕ ΜΟΝΤΕΛΑ ΤΥΠΟΥ ARMA ΚΑΙ ΔΥΝΑΜΙΚΑ ΜΟΝΤΕΛΑ.....	55
2.3. ΑΠΟΤΕΛΕΣΜΑΤΑ.....	61
2.4. ΣΥΜΠΕΡΑΣΜΑΤΑ .....	63
<b>ΚΕΦΑΛΑΙΟ 3</b>	<b>65</b>
ΠΑΡΑΛΛΗΛΗ ΑΝΑΓΝΩΡΙΣΗ ΤΩΝ ΤΕΛΕΣΤΩΝ ΚΑΙ ΤΗΣ ΤΑΞΗΣ ΠΟΛΥ-ΜΕΤΑΒΛΗΤΩΝ ΜΟΝΤΕΛΩΝ ΜΕΙΚΤΩΝ ΔΙΕΡΓΑΣΙΩΝ - ARMA.....	65
3.1. ΕΙΣΑΓΩΓΗ.....	66
3.2 ΕΠΑΝΑΔΙΑΤΥΠΩΣΗ ΤΟΥ ΠΡΟΒΛΗΜΑΤΟΣ .....	68
3.3. ΠΑΡΟΥΣΙΑΣΗ ΤΩΝ ΣΥΓΚΡΙΝΟΜΕΝΩΝ ΚΡΙΤΗΡΙΩΝ .....	70
3.5. ΣΥΜΠΕΡΑΣΜΑΤΑ .....	84
<b>ΚΕΦΑΛΑΙΟ 4</b>	<b>85</b>
ΜΟΝΤΕΛΟΠΟΙΗΣΗ ΚΑΙ ΕΚΤΙΜΗΣΗ ΤΗΣ ΔΙΑΚΥΜΑΝΣΗΣ ΤΗΣ ΖΗΤΗΣΗΣ ΤΟΥ ΗΛΕΚΤΡΙΚΟΥ ΦΟΡΤΙΟΥ ΤΟΥ ΕΛΛΗΝΙΚΟΥ ΔΙΚΤΥΟΥ ΗΛΕΚΤΡΙΚΗΣ ΕΝΕΡΓΕΙΑΣ.....	85
4.1. ΕΙΣΑΓΩΓΗ.....	86
4.2. ΠΡΟΕΤΟΙΜΑΣΙΑ ΤΩΝ ΔΕΔΟΜΕΝΩΝ.....	88
4.3. ΜΟΝΤΕΛΟΠΟΙΗΣΗ ΤΩΝ ΕΠΕΞΕΡΓΑΣΜΕΝΩΝ ΔΕΔΟΜΕΝΩΝ ΜΕΣΩ ΔΙΕΡΓΑΣΙΑΣ ΤΥΠΟΥ ARMA.....	92
<i>4.3.1. Σύγκριση Κριτηρίων</i> .....	97
4.4 ΕΚΤΙΜΗΣΗ ΤΗΣ ΔΙΑΚΥΜΑΝΣΗΣ ΤΗΣ ΖΗΤΗΣΗΣ ΤΟΥ ΗΛΕΚΤΡΙΚΟΥ ΦΟΡΤΙΟΥ.....	100

4.4.1 Μηνιαία Εκτίμηση της Διακύμανσης Φορτίου - Σύγκριση Κριτηρίων	101
4.4.2 Εβδομαδιαία Εκτίμηση της Διακύμανσης Φορτίου - Σύγκριση Κριτηρίων	102
4.4.3 Εκτίμηση της Διακύμανσης Φορτίου χρησιμοποιώντας μοντέλα SARIMA.	106
4.4.4 Αποτελέσματα	108
4.5. ΣΥΜΠΕΡΑΣΜΑΤΑ .....	115
<b>ΚΕΦΑΛΑΙΟ 5</b>	<b>118</b>
ΜΟΝΤΕΛΟΠΟΙΗΣΗ ΤΗΣ ΜΕΤΑΒΟΛΗΣ ΤΗΣ ΑΝΤΙΣΤΑΣΗΣ ΤΟΥ ΕΔΑΦΟΥΣ ΧΡΗΣΙΜΟΠΟΙΩΝΤΑΣ ΜΟΝΤΕΛΑ ΜΕΙΚΤΩΝ ΔΙΕΡΓΑΣΙΩΝ - ARMA: ΣΥΓΚΡΙΣΗ ΚΡΙΤΗΡΙΩΝ .....	118
5.1. ΕΙΣΑΓΩΓΗ.....	119
5.2. ΜΟΝΤΕΛΟΠΟΙΗΣΗ ΤΩΝ ΔΕΔΟΜΕΝΩΝ ΚΑΙ ΣΥΓΚΡΙΣΗ ΚΡΙΤΗΡΙΩΝ.....	123
5.2.1 Μοντελοποίηση δεδομένων	123
5.2.2. Σύγκριση κριτηρίων	124
5.2.3 Αποτελέσματα	125
5.3. ΣΥΜΠΕΡΑΣΜΑΤΑ .....	135
<b>ΚΕΦΑΛΑΙΟ 6</b>	<b>136</b>
ΠΕΡΙΛΗΨΗ, ΓΕΝΙΚΑ ΣΥΜΠΕΡΑΣΜΑΤΑ, ΠΑΡΑΠΕΡΑ ΈΡΕΥΝΑ.....	136
<b>ΠΑΡΑΡΤΗΜΑ Α</b>	<b>143</b>
ΤΕΧΝΗΤΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ .....	143
<b>ΒΙΒΛΙΟΓΡΑΦΙΑ</b>	<b>148</b>



## ΕΙΣΑΓΩΓΗ

Ως σήμα μπορούμε να θεωρήσουμε μια φυσική ποσότητα  $x$  η οποία μεταβάλλεται ως μια συνάρτηση με ανεξάρτητη μεταβλητή  $n$ . Τυπικά αυτός ο δείκτης, αντιπροσωπεύει το χρόνο. Πολλά σήματα είναι χρήσιμο να αντιμετωπίζονται ως στοχαστικά. Αυτό στην πράξη σημαίνει ότι αν εκτελέσουμε το πείραμα που παράγει τις μετρήσεις επανειλημμένως θα λαμβάνονται κάθε φορά διαφορετικές παρατηρήσεις (*observations*) του  $x$ . Ένα στοχαστικό σήμα περιγράφεται ολοκληρωμένα από τα στατιστικά του στοιχεία, δηλαδή τη μέση τιμή (*mean value*) και τη διασπορά του (*variance*).

Μια διακριτή στάσιμη στοχαστική διεργασία (*discrete-time stationary stochastic process*), στο εξής αναφερόμενη ως *διεργασία* (*process*), είναι ένα σύνολο από τυχαίες μεταβλητές (*variables*) όπου για οποιαδήποτε αποδεκτά  $n_1, n_2, \dots, n_N$  και για μια τυχαία τιμή του  $k$ , η συνάρτηση πυκνότητας της πιθανότητας, (*probability density function – p.d.f*), του διανύσματος  $\{x_{n_1}, x_{n_2}, \dots, x_{n_N}\}$  ισούται με την αντίστοιχη *p.d.f* του διανύσματος  $\{x_{n_1+k}, x_{n_2+k}, \dots, x_{n_N+k}\}$  [1].

$N$  παρατηρήσεις μιας διεργασίας  $x$  μπορούν να γραφτούν ως ένα διάνυσμα  $\mathbf{x}$  με διαστάσεις  $N \times 1$ .

$$\mathbf{x} = [x_{n_1} \ x_{n_2} \ x_{n_3} \ \dots \ x_{n_N}]^T \quad (\text{E-1})$$

Η πραγμάτωση (*realization*) του  $\mathbf{x}$  αναφέρεται ως σήμα (*signal*) ή χρονική σειρά (*time series*). Επίσης η συνάρτηση πυκνότητας της πιθανότητας μιας διεργασίας συμβολίζεται ως  $f(\mathbf{x})$ . Οι πραγματώσεις των στοχαστικών συντελεστών  $x_n$  αναφέρονται ως παρατηρήσεις. Θεωρούμε ένα αδιάλειπτο (*uninterrupted*) δείγμα ενός σήματος  $\{x_{n_1}, x_{n_2}, \dots, x_{n_N}\}$  όπου  $n_i = i, i = 1, \dots, N$ . Η στατιστική ανάλυση του σήματος αυτού ονομάζεται ανάλυση χρονικής σειράς (*time series analysis*).

Η μέση τιμή της διεργασίας συμβολίζεται με  $\mu$  και ορίζεται ως:

$$\mu = E\{x_n\} \quad (\text{E-2})$$

Η πλειοψηφία των σημάτων θεωρείται ότι έχουν μέση τιμή μηδέν,  $\mu = 0$ .

Η διασπορά ορίζεται ως:

$$\sigma_x^2 = E\{x_n^2\} \quad (\text{E-3})$$

Ένα μοντέλο (*model*) είναι ικανό να περιγράψει τις στατιστικές ιδιότητες μιας διεργασίας. Αυτό σημαίνει ότι ένα μοντέλο είναι σε θέση να παράγει, για οποιαδήποτε αποδεκτά  $n_1, n_2, \dots, n_N$  και για μια τυχαία τιμή του  $k$ , τη συνάρτηση πυκνότητας της πιθανότητας,  $f(\mathbf{x})$  του διανύσματος  $\{x_{n_1}, x_{n_2}, \dots, x_{n_N}\}$ . Μια καλή τακτική για να περιγράψουμε μια διεργασία είναι η χρησιμοποίηση ενός *παραμετρικού μοντέλου* (*parametric model*). Αυτό είναι ένα μοντέλο που εξαρτάται από ένα παραμετρικό διάνυσμα  $\theta$ . Η συνάρτηση πυκνότητας της πιθανότητας αυτού του διανύσματος ορίζεται ως  $f(\mathbf{x}; \theta)$ . Δυο μοντέλα θεωρούνται ισοδύναμα όταν παράγουν την ίδια συνάρτηση πιθανοτήτων  $f(\mathbf{x})$ . Το σύνολο όλων των συναρτήσεων κατανομής (*distribution function*) που εμπεριέχουν τα μοντέλα  $f(\mathbf{x}; \theta)$  για όλες τις έγκυρες τιμές του  $\theta$  ονομάζεται *μοντελική δομή* (*model structure*)  $F$ . Παραδείγματα παραμετρικών μοντέλων είναι τα ακολουθιακά μοντέλα *AR*( $\theta$ ) (*Auto Regressive*), ακολουθιακά μοντέλα μεικτών διεργασιών *ARMA*( $p, q$ ) (*Auto Regressive Moving Average*), *ARIMA* (*Auto Regressive Integrated Moving Average*), και περιοδικά μοντέλα *ARIMA* που ονομάζονται *SARIMA* (*Seasonal Auto Regressive Integrated Moving Average*).

Στη ανάλυση χρονικών σειρών εκτός από παραμετρικά μοντέλα (*parametric models*) εφαρμόζονται και μη παραμετρικές μέθοδοι (*non parametric techniques*). Με αυτόν τον τρόπο κανένα συγκεκριμένο μοντέλο για την επεξεργασία των δεδομένων δε χρησιμοποιείται. Ένα παράδειγμα ενός μη παραμετρικού εκτιμητή (*non parametric estimator*) είναι το *περιοδογράφημα* (*periodogram*) ή *ακατέργαστο FFT* (*raw FFT*) ως εκτιμητή για το φάσμα ισχύος (*power spectrum*). Ουσιαστικά το *περιοδογράφημα* αφορά το γρήγορο διακριτό μετασχηματισμό *Fourier* (*Fast Fourier Transform - FFT*) των δεδομένων.

Το πλεονέκτημα των μη παραμετρικών τεχνικών είναι η ανεξαρτησία τους από ένα συγκεκριμένο μοντέλο για κάποια συγκεκριμένα δεδομένα. Έχουν όμως το μειονέκτημα ότι σε αρκετές περιπτώσεις είναι ανακριβή.

Τα παραμετρικά μοντέλα συνιστούν πιο ακριβείς μεθόδους και στις περισσότερες περιπτώσεις τις ακριβέστερες μεθόδους, εάν χρησιμοποιηθεί η σωστή μοντελική δομή. Εάν όμως το μοντέλο δεν μπορεί να περιγράψει ικανοποιητικά όλες τις σημαντικές ιδιότητες της διεργασίας η απόδοσή του είναι φτωχή. Μια λύση σε αυτό το πρόβλημα είναι η επιλογή της τάξης  $\theta$  μοντέλου. Με αυτόν τον τρόπο η μοντελική δομή καθορίζεται αυτόματα από τα δεδομένα, χρησιμοποιώντας στατιστικές μεθόδους επιλογής της τάξης  $\theta$ . Εναλλακτικά η μοντελική δομή μπορεί να καθοριστεί με παρέμβαση του χρήστη (*user interaction*).

Το πλεονέκτημα που έχουν οι αυτόματες τεχνικές ανάλυσης είναι ο ακριβής εντοπισμός των στατιστικών ιδιοτήτων των αρχικών δεδομένων, κάτι που δεν είναι δυνατό στις μεθόδους που απαιτούν την παρέμβαση του χρήστη. Επίσης οι τελευταίες είναι σχεδόν ανεφάρμοστες, αφού σημαίνει ότι ο χρήστης πρέπει να έχει βαθιά και εξειδικευμένη γνώση της θεωρίας επεξεργασίας σημάτων (π.χ. στην περίπτωση επεξεργασίας σημάτων radar όπου ένας πολύ μεγάλος αριθμός σημάτων αναλύεται ανά δευτερόλεπτο).

## **E.1. Ταυτοποίηση Συστήματος (*System Identification*)**

Τα τελευταία 40 χρόνια έχουν επιτελεστεί σημαντικές εξελίξεις τόσο στη θεωρία όσο και στην εφαρμογή των γραμμικών (*linear*) συστημάτων έχοντας ως εφιαλτήριο τα αποτελέσματα της έρευνας του Kalman, [2], και των Kalman και Bucy [3]. Μέσω αυτής της διαδικασίας έγινε επίσης σημαντική πρόοδος στην κατανόηση τόσο της άλγεβρας όσο και της τοπολογικής δομής των γραμμικών δυναμικών συστημάτων (*linear dynamic models*) με τον περισσότερο όγκο δουλειάς να προέρχεται από τον τομέα της μηχανικής (*engineering*) και κυρίως του τομέα ελέγχου (*control engineering*). Παράλληλα τα γραμμικά συστήματα χρησιμοποιήθηκαν για τη μοντελοποίηση και τη στατιστική ανάλυση δεδομένων προερχόμενων από επεξεργασία σημάτων (*signal processing*). Πρέπει να τονιστεί ότι οι περιπτώσεις που μελετήθηκαν πρώτες αφορούσαν βαθμωτά (*scalar*) συστήμα-

τα. Συγκεκριμένα, ηλεκτρολόγοι μηχανικοί όπως οι Ljung [4], και Young [5], ανέπτυξαν αλγόριθμους σχετικά με την εκτίμηση μοντέλων σε πραγματικό χρόνο (*real time*). Παράλληλα, αναλυτές στατιστικών σειρών, ασχολούμενοι με προβλήματα τα οποία προέρχονταν από διάφορα επιστημονικά πεδία ανέπτυξαν θεωρίες και αλγόριθμους οι οποίοι αρχικά λειτούργησαν για την εκτίμηση μοντέλων *off line*. Συνοπτικά αναφέρονται οι Hannan [6], Box και Jenkins [7], Akaike [8]. Επίσης στατιστικοί επιστήμονες όπως ο Whittle [9], ανέπτυξαν την απαιτούμενη ασυμπτωτική θεωρία (*asymptotic theory*) η οποία σχετίζεται με τις διεργασίες εκτίμησης.

Η χρήση μαθηματικών μοντέλων (συνεχούς, *continuous*, ή διακριτού, *discrete*, χρόνου) αποτελεί έναν κοινά κατανοητό τρόπο περιγραφής δυναμικών συστημάτων. Υπάρχουν δυο βασικές κατηγορίες κατασκευής τέτοιων μαθηματικών μοντέλων:

- *Μοντελοποίηση μέσω της γνώσης των φυσικών παραμέτρων του συστήματος (Physical Modeling)*
- *Ταυτοποίηση Συστήματος*

Στην πρώτη κατηγορία η δημιουργία του δυναμικού μοντέλου απαιτεί τη γνώση των φυσικών παραμέτρων του συστήματος και βασίζεται στους βασικούς νόμους της Φυσικής, για παράδειγμα τους νόμους του Νεύτωνα. Αντίθετα, η δεύτερη κατηγορία χρησιμοποιείται όταν η γνώση τέτοιου είδους στοιχείων και λεπτομερειών είναι περιορισμένη. Η συμπεριφορά εισόδου και εξόδου του συστήματος μπορεί να επιτευχθεί μέσω της μεθόδου ταυτοποίησης η οποία βασίζεται στη διακρίβωση και ρύθμιση του μοντέλου μέσω πειραματικών δεδομένων και μετρήσεων.

Για χάρη της ορολογίας αναφέρονται οι παρακάτω περιπτώσεις:

- *Μαύρο κουτί (black box)*: Ονομάζεται το μαθηματικό δυναμικό μοντέλο που προκύπτει χωρίς να ληφθεί υπόψη κανένα από τα φυσικά χαρακτηριστικά του συστήματος.

- *Άσπρο κουτί (white box)* : Ονομάζεται το μαθηματικό δυναμικό μοντέλο που προκύπτει βασισμένο εξ ολοκλήρου στα φυσικά χαρακτηριστικά του συστήματος

- *Γκρι κουτί (grey box)* : Ονομάζεται το μαθηματικό δυναμικό μοντέλο κάποια στοιχεία του οποίου βασίζονται στα φυσικά χαρακτηριστικά του συστήματος

Με βάση τα παραπάνω κάποιος μπορεί να καταλάβει ότι η μέθοδος της ταυτοποίησης συστήματος δεν μπορεί να θεωρηθεί ότι υποκαθιστά τη μοντελοποίηση μέσω της γνώσης φυσικών παραμέτρων, αφού υπάρχει περίπτωση η ταυτοποίηση να βασίζεται σε μοντελικές δομές οι οποίες να έχουν τη βάση τους στις φυσικές παραμέτρους του συστήματος. Οι μοντελικές αυτές δομές διακρίνονται στις δυο παρακάτω κατηγορίες:

- *Μη παραμετρικές*
- *Παραμετρικές*


Σε κάθε περίπτωση η μοντελοποίηση μέσω της γνώσης φυσικών παραμέτρων θα σχετίζεται πάντοτε με την *παραμετρική μοντελική δομή*. Το κοινό σημείο και των δυο κατηγοριών μοντελικών δομών είναι πως εξαρτώνται από τον τύπο της εξωτερικής διέγερσης που εφαρμόζεται στο σύστημα και η οποία μπορεί να είναι:

- *Στιγμιαία διέγερση (Instantaneous excitation).*
- *Περιοδική διέγερση (Periodic excitation)*
- *Ψευδο – τυχαία περιοδική διέγερση (Pseudo – Random periodic excitation)*
- *Στοχαστική διέγερση (Stochastic excitation)*

Η θεωρία των γραμμικών συστημάτων, σε συνδυασμό με την ανάλυση χρονικών σειρών και την ασυμπτωτική θεωρία (*asymptotic theory*) αποτελούν τη βάση των σύγχρονων μεθόδων *ταυτοποίησης συστημάτων*. Ο όρος *ταυτοποίηση συστημάτων* μπορεί να μεταφραστεί και ως *μοντελοποίηση δυναμικών συστημάτων χρησιμοποιώντας πειραματικά δεδομένα*. Ο τελευταίος γενικός ορισμός υποδηλώνει το ότι η *ταυτοποίηση συστημάτων* μπορεί να εφαρμοστεί σε ένα πλήθος εφαρμογών, όπως:

- *Ανάλυση δυναμικών βιολογικών συναρτήσεων, όπως επιδράσεις φαρμάκων, ρύθμιση των κτύπων της καρδιάς κ.λ.π.*
- *Επεξεργασία σημάτων*
- *Αναγνώριση βιομηχανικών διεργασιών καθώς και διαχείριση και έλεγχο αυτών.*
- *Στα οικονομικά με τη μοντελοποίηση των τιμών των μετοχών.*
- *Αναγνώριση των δυναμικών ιδιοτήτων μεγάλων κατασκευών, όπως πύργοι, γέφυρες, φράγματα κ.λ.π.*

Το κοινό χαρακτηριστικό όλων των προαναφερθέντων παραδειγμάτων είναι ότι η δυναμική τους συμπεριφορά μπορεί να περιγραφεί σχηματικά ως ακολούθως:



Εικ. E-1. Δυναμικό σύστημα με είσοδο (*input*)  $u(t)$  έξοδο (*output*)  $y(t)$  και θόρυβο (*disturbance*)  $v(t)$

Το παραπάνω σύστημα οδηγείται από την είσοδο  $u(t)$  και επηρεάζεται από το θόρυβο  $v(t)$ . Υπάρχουν περιπτώσεις όπου ο χρήστης μπορεί να ρυθμίσει και να ελέγξει την είσοδο  $u(t)$  όχι όμως και το θόρυβο  $v(t)$ . Ένα άλλο πιθανό σενάριο είναι η πραγματική είσοδος να είναι άγνωστη οπότε για κάποιες εφαρμογές να μην μπορεί να ελεγχθεί (*uncontrollable input*). Η έξοδος  $y(t)$  περιγράφει πώς το σύστημα αντιδρά ή ανταποκρίνεται τόσο στην είσοδο όσο και στο θόρυβο. Λαμβάνοντας αυτό υπόψη μπορούμε να πούμε πως η έξοδος θα είναι ένα μείγμα της δυναμικής απόκρισης (*dynamic response*) του συστήματος και των χαρακτηριστικών τόσο της εισόδου όσο και του θορύβου. Επίσης μπορούμε με ασφάλεια να δηλώσουμε πως η παρελθούσα συμπεριφορά της εισόδου μπορεί να επηρεάσει την παρούσα συμπεριφορά της εξόδου. Με άλλα λόγια το δυναμικό σύστημα έχει «μνήμη».

### E.1.1. Μη παραμετρικές μοντελικές δομές

Γραφικές παραστάσεις, πίνακες δεδομένων, συναρτησιακές σχέσεις είναι μερικά παραδείγματα «μέσων» που χρησιμοποιούνται για την περιγραφή των μη παραμετρικών μοντελικών δομών. Κάποιοι τρόποι ανάλυσης των δεδομένων που αντλούνται από τα προαναφερθέντα «μέσα» είναι:

- *Μεταβατική ή προσωρινή ανάλυση (transient response).*
- *Ανάλυση συχνοτήτων (frequency analysis).*
- *Ανάλυση συσχέτισης (correlation analysis).*
- *Φασματική ανάλυση (spectral analysis).*

Η μεταβατική ή προσωρινή ανάλυση χρησιμοποιείται όταν η απόκριση του συστήματος (*system response*) είναι μεταβατική ή προσωρινή, δηλαδή έχει δημιουργηθεί βάση μιας στιγμιαίας διέγερσης, όπως είναι μια συνάρτηση βήματος (*step function*) ή ένας παλμός (*impulse response*). Η ανάλυση συχνοτήτων εφαρμόζεται όταν η διέγερση είναι ντετερμινιστική είτε περιοδική είτε ψευδο-τυχαία περιοδική. Η φασματική ανάλυση καθώς και η ανάλυση συσχέτισης εφαρμόζονται σε στάσιμα συστήματα με στοχαστική διέγερση.

Οι παραδοσιακές μη παραμετρικές τεχνικές ταυτοποίησης συστημάτων βασίζονται πρωταρχικά στους μετασχηματισμούς Fourier [10]. Οι μετασχηματισμοί Fourier αποτελούν χρήσιμα μαθηματικά εργαλεία τα οποία είναι ιδανικά για τη θεωρητική ανάλυση των δυναμικών συστημάτων. Ο μετασχηματισμός Fourier μιας σειράς που έχει υποστεί ομοιόμορφη δειγματοληψία (*uniform sampled data*) επιτυγχάνεται μέσω του *Γρήγορου Μετασχηματισμού Fourier (Fast Fourier Transform - FFT)*. Οι αλγόριθμοι που βασίζονται στη μέθοδο *FFT* χρησιμοποιήθηκαν κατά κύριο λόγο στην ταυτοποίηση συστημάτων καθώς και στην επεξεργασία σημάτων, [11]. Εξακολουθούν να είναι δημοφιλείς λόγω της ταχύτητας και της αξιοπιστίας τους.

Ο μετασχηματισμός Fourier θεωρεί κατά κανόνα πως το πλήθος των δεδομένων είναι άπειρο και ότι αυτά τα δεδομένα είναι *περιοδικά (periodic data)* γεγο-

νός που σαφέστατα δεν ισχύει όταν η δειγματοληπτική απόκριση ενός συστήματος (*sampled system response*) προέρχεται από στοχαστική διέγερση (*stochastic excitation*). Τα αρχεία δεδομένων (*data records*) τέτοιων αποκρίσεων είναι σίγουρο πως έχουν πεπερασμένο πλήθος στοιχείων (*finite length*) και ότι δεν είναι περιοδικά (*non - periodic*).

Συνεπώς υπάρχουν ορισμένοι περιορισμοί στη χρήση αλγορίθμων που βασίζονται σε *FFT*. Οι τρεις βασικότεροι είναι τα λάθη διαφυγής (*leakage errors*), τα οποία προκύπτουν λόγω της μη περιοδικότητας των αρχικών δεδομένων, η συχνότητα δειγματοληψίας και το φαινόμενο *alias* το οποίο αν δε ληφθεί υπόψη υπάρχει σοβαρή πιθανότητα να οδηγήσει σε παραμόρφωση (*distortion*) της ανάλυσης των δεδομένων. Μέθοδοι για την ελαχιστοποίηση της επίδρασης των προαναφερθέντων παραγόντων, οι οποίοι συσχετίζονται άμεσα μεταξύ τους [13], αναφέρονται από τον Kay [12], επειδή όμως εφαρμόζονται σε ένα πεπερασμένο αρχικό σύνολο δεδομένων έχουν ως αποτέλεσμα την περιορισμένη ανάλυση συχνοτήτων, άρα και τη λανθασμένη εκτίμηση του συστήματος (*inaccurate system estimates*).

### **E.1.2. Παραμετρικές μοντελικές δομές**

Οι παραμετρικές μοντελικές δομές χαρακτηρίζονται από την υπόθεση πως το μαθηματικό μοντέλο προκύπτει από ένα σύνολο παραμέτρων, οι οποίες εκτιμώνται αργότερα κατά τη διαδικασία της ταυτοποίησης του συστήματος. Στην Εικόνα E-1 είδαμε ότι η έξοδος του συστήματος  $y(t)$  επηρεάζεται από κάποιο θόρυβο  $v(t)$ . Η μορφή ενός διακριτού χρόνου παραμετρικού μοντέλου (*discrete time parametric model*) εξαρτάται από το αν η είσοδος  $u(t)$  είναι μετρήσιμη ή όχι. Αν είναι μετρήσιμη τότε το παραμετρικό μοντέλο θα περιλαμβάνει ένα ντετερμινιστικό όρο μαζί με ένα στοχαστικό ο οποίος θα περιγράφει το θόρυβο. Αν η είσοδος είναι άγνωστη τότε τη μεταχειριζόμαστε στοχαστικά, δηλαδή η περιγραφή τόσο του θορύβου όσο και της εισόδου θα γίνει από έναν και μόνο στοχαστικό όρο.



### E.1.3. Μοντελικές δομές α) με ντεντερμινιστική είσοδο, β) στοχαστική είσοδο

α) Η χαρακτηριστική μοντελική δομή εισόδου / εξόδου που χρησιμοποιείται για τη μοντελοποίηση γραμμικών χρονικά αμετάβλητων δυναμικών συστημάτων (*linear time invariant dynamic systems*) διεγερμένων από ντεντερμινιστική είσοδο είναι ένα μοντέλο *ARMAX*, το οποίο ουσιαστικά είναι ένα μοντέλο *ARMA* με μια εξωτερική (*eXternal*) είσοδο.

$$\mathbf{A}(q)y(t) = \mathbf{B}(q) \mathbf{u}(t) + \mathbf{C}(q) \mathbf{e}(t) \quad (\text{E-4})$$

$\mathbf{A}(q) = I + a_1 q^{-1} + \dots + a_n q^{-n}$ ,  $a_1, \dots, a_n$  είναι οι συντελεστές του ακολουθιακού μοντέλου *AR* με τάξη  $n$ .

$\mathbf{C}(q) = I + c_1 q^{-1} + \dots + c_r q^{-r}$ ,  $c_1, \dots, c_r$  είναι οι συντελεστές του μοντέλου *MA* (*Moving Average*) με τάξη  $r$ .

$\mathbf{B}(q) = b_1 + b_2 q^{-1} + \dots + b_m q^{-m+1}$ ,  $b_1, \dots, b_m$  είναι οι συντελεστές της εξωτερικής εισόδου  $\mathbf{u}(t)$  με τάξη  $m$ .

Η στοχαστική είσοδος  $\mathbf{e}(t)$  (*innovations*) ισοδυναμεί με τις διεργασίες θορύβου (*noise*) και λαθών εκτίμησης (*prediction errors*). Επίσης ο όρος  $q$  είναι ο αναδρομικός τελεστής (*back-shift operator*).

β) Αν η είσοδος είναι μια στοχαστική διεργασία που δεν δύναται να μετρηθεί τότε το μοντέλο *ARMAX* δεν είναι πια το καταλληλότερο για να χρησιμοποιηθεί. Σε αυτή την περίπτωση χρησιμοποιείται το απλό μοντέλο *ARMA*:

$$\mathbf{A}(q)y(t) = \mathbf{B}(q) \mathbf{u}(t) \quad (\text{E-5})$$

Συμπερασματικά μπορούμε να πούμε πως η επιλογή της μοντελικής δομής εξαρτάται από τη φύση της εισόδου, ντεντερμινιστική - δηλαδή μετρήσιμη και γνωστή -, ή στοχαστική - δηλαδή άγνωστη και μη μετρήσιμη. Επίσης μια παραμετρική μοντελική δομή ονομάζεται πολύ-μεταβλητή (*multivariate - MV*) όταν περιλαμβάνει πολλές μεταβλητές. Αν υπάρχουν και πολλές έξοδοι χαρακτηρίζεται ως πολυ-μοντελική (*multi-model*) δομή. Αν έχει μια μόνο έξοδο ως βαθμωτή (*univariate - scalar*) μοντελική δομή.

## E.2. Περίληψη Διατριβής

Η διατριβή αυτή αποτελείται από 6 κεφάλαια. Στο πρώτο κεφάλαιο παρουσιάζεται η μέθοδος για ταυτόχρονη αναγνώριση των παραμέτρων και της τάξης χρονικά αμετάβλητων πολύ-μεταβλητών (*MutliVariate - MV*) ακολουθιακών (*Auto-Regressive - AR*) μοντέλων υπό την παρουσία θορύβου, ως επέκταση της επιτυχημένης εφαρμογής του αλγόριθμου πολύ-μοντελικού διαμελισμού για τη βαθμωτή περίπτωση. Επίσης μέσω εξομοιώσεων αποδεικνύεται ότι η μέθοδος είναι επιτυχής και για χρονικά μεταβαλλόμενα *MV AR* μοντέλα. Η απόδοση του προτεινόμενου αλγόριθμου συγκρίνεται με αυτήν άλλων καταξιωμένων μεθόδων.

Στο δεύτερο κεφάλαιο εφαρμόζεται η μέθοδος πολυμοντελικού διαμελισμού με στόχο την αναγνώριση ενός μοντέλου που θα περιγράφει την κίνηση ενός δικτύου υπολογιστών και θα είναι σε θέση να εντοπίζει πιθανές ανωμαλίες. Τα δεδομένα που χρησιμοποιούνται είναι πραγματικά, προέρχονται από το δίκτυο του ΤΕΙ Αθήνας, είναι εύκολα προσβάσιμα και αφορούν την εκμετάλλευση του εύρους ζώνης (*bandwidth utilization*) του δικτύου. Προηγείται επεξεργασία των δεδομένων αυτών με στόχο την εξαγωγή πληροφοριών που αφορούν την κανονική συμπεριφορά ενός δικτύου και την τελική μοντελοποίησή της μέσω Περιοδικών Μοντέλων Μεικτών Διεργασιών (*Auto Regressive Integrated Moving Average*) *SARIMA*.

Το τρίτο κεφάλαιο είναι προέκταση της έρευνας του πρώτου κεφαλαίου και πραγματεύεται την εφαρμογή του αλγόριθμου πολυ-μοντελικού διαμελισμού για την ταυτόχρονη αναγνώριση της τάξης και των παραμέτρων πολύ-μεταβλητών μοντέλων μεικτών διεργασιών (*MV Autoregressive Moving Average - ARMA*) υπό την παρουσία θορύβου. Συμπληρωματικά μέσω εξομοιώσεων αποδεικνύεται πως ο προτεινόμενος αλγόριθμος μπορεί να εντοπίσει τυχόν αλλαγές της τάξης του μοντέλου σε πραγματικό χρόνο ακόμα και όταν η πολυπλοκότητα των μοντέλων αυξάνεται. Όπως και στο πρώτο κεφάλαιο η απόδοση του προτεινόμενου αλγόριθμου συγκρίνεται με αυτήν άλλων καταξιωμένων μεθόδων.

Στο τέταρτο κεφάλαιο διερευνάται το πρόβλημα της αποτελεσματικής παραμετροποίησης, μοντελοποίησης και εκτίμησης της ζήτησης του ηλεκτρικού φορτίου χρησιμοποιώντας μοντέλα *ARMA* με τη χρήση πραγματικών δεδομένων. Στο πρώτο μέρος του κεφαλαίου αποδεικνύεται η δυνατότητα εφαρμογής ενός μοντέλου *ARMA* έπειτα από ειδική επεξεργασία, *off-line*, των δεδομένων η οποία τους αφαιρεί την περιοδικότητα. Ακολούθως στα δεδομένα προστίθεται θόρυβος και πραγματοποιείται σύγκριση της προτεινόμενης μεθόδου -φίλτρο Λαϊνιώτη (Multi Model Partition Filter *MMPF*)- με άλλα καταξιωμένα κριτήρια με στόχο την επιτυχή αναγνώριση της τάξης και των συντελεστών του υπάρχοντος μοντέλου *ARMA*, όπως και στο προηγούμενο κεφάλαιο. Στη συνέχεια διερευνάται ποιες από τις μεθόδους που χρησιμοποιήθηκαν μπορούν να εκτιμήσουν τη διακύμανση του ηλεκτρικού φορτίου για μια εβδομάδα χωρίς να υπερβούν ένα συγκεκριμένο όριο λάθους, (2.5%). Στα συγκρινόμενα κριτήρια αυτή τη φορά προστίθενται και τα Τεχνητά Νευρωνικά Δίκτυα (Artificial Neural Networks-ANN). Επιπρόσθετα πραγματοποιείται η εκτίμηση της ημερήσιας μέγιστης ζήτησης φορτίου (daily peak forecast).

Στο τελευταίο μέρος πραγματοποιείται η μοντελοποίηση της ζήτησης του ηλεκτρικού φορτίου μέσω ενός μοντέλου *SARIMA*. Η μέθοδος πολυμοντελικού διαμελισμού εφαρμόζεται και πάλι με στόχο την αναγνώριση ενός μοντέλου που θα περιγράφει τη διακύμανση του φορτίου και θα είναι ικανό να εντοπίζει πιθανές μη περιοδικές ανωμαλίες όπως υψηλή ζήτηση (*peak load*) ή σφάλμα στη γραμμή (*blackout*).

Στο πέμπτο κεφάλαιο εφαρμόζονται μοντέλα *ARMA* με στόχο την αποτελεσματική παραμετροποίηση και μοντελοποίηση της μεταβολής της αντίστασης του εδάφους. Τα δεδομένα που χρησιμοποιήθηκαν είναι πραγματικά και το μοντέλο *ARMA* προέκυψε έπειτα από την *off-line* επεξεργασία τους. Στη συνέχεια προστίθεται θόρυβος στα δεδομένα και πραγματοποιείται σύγκριση της προτεινόμενης μεθόδου -φίλτρο Λαϊνιώτη (Multi Model Partition Filter *MMPF*)- με άλλα καταξιωμένα κριτήρια με στόχο την επιτυχή αναγνώριση της τάξης και των συ-

ντελεστών του υπάρχοντος μοντέλου ARMA, όπως και στο προηγούμενο κεφάλαιο. Ο σκοπός της σύγκρισης είναι να διαπιστωθεί το κατά πόσο χρήσιμο μπορεί να είναι το μοντέλο αυτό όταν τα δεδομένα περιέχουν υψηλό θόρυβο ή όταν χρειάζεται *on – line* μοντελοποίηση.

Τέλος στο έκτο κεφάλαιο συνοψίζονται τα βασικότερα συμπεράσματα αυτής της διατριβής καθώς και προτάσεις για παραπέρα έρευνα.

### **E.3. Summary of Thesis**

This thesis deals with the extension of the multi-model partitioning theory to multivariate models and its application to real cases such as computer networks, electric load demand forecasting and the variation of the grounding resistance during the year.

In the first chapter the multi-model partitioning theory is used for simultaneous order and parameter estimation of multivariate autoregressive models as an extension to the one proposed for the scalar case in [30]. Simulation experiments show that the proposed method successfully selects the correct model order and estimates the parameters accurately, in very few steps, even with a small sample size. They also show that the proposed method performs equally well when the complexity of the model is increased. The results are compared to those obtained using well-established order selection criteria namely (AIC [8], AICC [25-27], BIC [19], H & Q [23], DC and MDC [27, 32]). Finally, it is shown that the method is also successful in tracking model order changes, in real time [57].

The second chapter deals with adaptive network anomaly detection using bandwidth utilization data. The proposed method has two advantages: it is based on a powerful multi model partitioning filter, (MMPF) proposed by Lainiotis [33-35], known for its stability and well established in identification and modeling; secondly, it uses easy to find and collect datasets. Bandwidth use is the most common set of data and almost all network administrators monitor the bandwidth utilization for their servers, LAN/VLAN users, and network connections. The

proposed method uses past traffic data to learn and model the normal periodic behavior of a network connection. Either SARIMA (Seasonal Arima) or State-Space models can be used for the traffic pattern modeling. Several traffic anomalies are also modeled from the past experience. If the traffic pattern does not match the normal behavior of the network connection an anomaly is detected, and furthermore, when the pattern matches a known case, the type of anomaly is identified. Real traffic data were used and real world cases were tested from the TEI of Athens campus network. The applied adaptive multi-model partitioning filter identified successfully the unusual activities. The method can perform equally well in real-time using the sampling interval required by the network monitoring programs.

Chapter three applies the multi-model partitioning filter in order to perform simultaneous order and parameter estimation of Multivariate (MV) ARMA (Auto-Regressive Moving Average) models under the presence of noise. The aim of this chapter is not to add yet another ARMA model selection criterion to the rich literature in this area. Rather we focus on an extension to the model order selection criterion proposed for MV AR models by Pappas, Leros and Katsikas [57]. The proposed method successfully selects the correct model order in very few steps and identifies very accurately the ARMA parameters. Comparison with other established order selection criteria (AIC [8] and BIC [19]) shows that the method needs the shortest data set for successful order identification and accurate parameter estimation for all the simulated models, whereas the other criteria require longer data sets as the model order increases. The method performs equally well when the complexity of the MV ARMA model is increased. Finally, the method is capable of tracking, in real time, any model order changes.

Chapter 4 deals with efficient modeling and forecasting of the electricity demand load using real data. Firstly an appropriate deseasonalization [106-107] of the provided electricity demand load data covering the period from January 1st 2004 to December 31st 2005 is conducted. Then an AutoRegressive Moving Av-

erage (ARMA) model is fitted (off-line) on this data using the Corrected Akaike Information Criterion (AICC) [115]. The developed model is shown to fit the data in a successful manner.

The next step is to add noise to the real data provided. Four different estimation methods, namely the multi-model partitioning theory (MMPF), Corrected Akaike Information Criterion (AICC) [25-27], Akaike's Information Criterion (AIC) [8] and Schwarz's Bayesian Information Criterion (BIC) [19], use the new noisy data set in order to perform simultaneous order and parameter estimation of Multivariate (MV) ARMA (AutoRegressive Moving Average) models under the presence of noise. Furthermore, we investigated which of the above mentioned methods are able to effectively perform weekly load demand forecasting without exceeding the current industrial standard average mean error of 2.5%. An Artificial Neural Network, whose architecture is described in Appendix A, is also added to the compared criteria. Moreover a next day peak load demand forecasting is also performed.

The second part of chapter four proposes an adaptive method based on the multi model partitioning filter, (MMPF) for short term electric load forecasting using real data. Grid utilization is initially modeled using a multiplicative seasonal ARIMA (p, d, q) x (P, D, Q) (*SARIMA*) model. The proposed method uses past data to learn and model the normal periodic behavior of the electric grid. Either ARMA or State-Space models can be used for the load pattern modeling. Load anomalies such as unexpected peaks that may appear during the summer or unexpected faults (blackouts) are also modeled. If the load pattern does not match the normal behavior of the load, an anomaly is detected furthermore, when the pattern matches a known case of anomaly, the type of anomaly is identified. The applied adaptive multi-model partitioning filter identified successfully both normal periodic behavior and any unusual activity of the electric grid. The performance of the proposed method is compared to that of the produced *SARIMA* model. This work can be useful in the studies that concern electricity consumption and electricity

prices forecasts giving the possibility to the electricity providers, retailers and regulatory authorities to supply uninterrupted energy at a low cost.

Chapter 5 addresses the problem of modeling the variation of the grounding resistance during the year. An AutoRegressive Moving Average (ARMA) model is fitted (off-line) on the provided actual data using the Corrected Akaike Information Criterion (AICC) [125-129]. Difficulties occur when the provided data include noise or errors and also when on line/adaptive modeling is required. For this reason noise is added to the real data and the multi-model partitioning filter is used for the solution of the aforementioned problem. The simulations show that the proposed method succeeds in selecting the correct ARMA model order and estimates the parameters accurately in very few steps, even with a small sample size. For validation purposes the proposed method was compared with three other established order selection criteria (AICC [25-27], AIC [8], BIC [19]) and presented very good results. The proposed method can be extremely useful in the design of electrical installations, since the variation of the grounding resistance during the year affects significantly power systems performance and must be definitely considered.

## Κεφάλαιο 1

Παράλληλη αναγνώριση των τελεστών και της τάξης πολυ-μεταβλητών ακολουθιακών μοντέλων.



## 1.1. Εισαγωγή

**Η** προσαρμογή ενός MV AR μοντέλου σε μια συγκεκριμένη χρονική σειρά χρησιμοποιείται σε αρκετά επιστημονικά πεδία όπως :

- η αναγνώριση συστημάτων,
- η γραμμική εκτίμηση (*liner prediction*),
- η ανάλυση φάσματος και πολλά άλλα.

Επίσης εμφανίζεται και σε μια σειρά από εφαρμογές όπως: [14]-[18]

- στον προσαρμοζόμενο έλεγχο (*adaptive control*),
- στην ανάλυση και τη σύνθεση της φωνής (*speech analysis and synthesis*),
- την επεξεργασία γεωφυσικών δεδομένων,
- την ανάλυση εγκεφαλικών (*EEG*) και καρδιακών σημάτων (*ECG*) κ.α.

Ένα *MV AR* μοντέλο,  $m$  μεταβλητών, τάξης  $\theta$  [ $AR(\theta)$ ], το οποίο αντιστοιχεί σε μια στατική χρονική σειρά διανυσμάτων  $\mathbf{y}$ , που έχουν επιλεγθεί σε  $k$  ( $k = 1, 2, \dots, I$ ) ισαπέχουσες χρονικές στιγμές ορίζεται ακολούθως:

$$\mathbf{y}_k = \sum_{i=1}^{\theta} \mathbf{A}_i \mathbf{y}_{k-i} + \mathbf{v}_k, \quad E[\mathbf{v}_k \mathbf{v}_k^T] = \mathbf{R} \quad (1-1)$$

$\mathbf{v}_k$  είναι το διάνυσμα του τυχαίου ανεξάρτητου θορύβου, με μήτρα διασποράς  $\mathbf{R}$ , διάσταση  $m$ , μέση τιμή  $\theta$  και οι  $m \times m$  πίνακες  $\mathbf{A}_1, \dots, \mathbf{A}_\theta$  αποτελούν τους συντελεστές του μοντέλου.

Το πρόβλημα μπορεί να περιγραφεί ως εξής:

Έστω ένα σύνολο δειγμάτων (*samples*) από μια διακριτή χρονική σειρά (*discrete time process*)  $\{\mathbf{y}(k), 0 \leq k \leq n-1\}$ . Το ζητούμενο είναι η εύρεση ενός συνόλου συντελεστών  $\{\mathbf{A}_i\}$  που θα οδηγήσουν στον βέλτιστο γραμμικό εκτιμητή  $\mathbf{y}(n)$  ο οποίος θα βασίζεται σε όλα τα προηγούμενα δείγματα έως και τη χρονική στιγμή  $n - 1$ :

$$\hat{\mathbf{y}}(n/n-1) = \sum_{i=1}^{\theta} \mathbf{A}_i \mathbf{y}(n-i) \quad (1-2)$$

Το διάνυσμα  $\hat{\mathbf{y}}(n/n-1)$  συμβολίζει την εκτίμηση του  $\mathbf{y}(n)$  και όπως προαναφέρθηκε βασίζεται σε όλες τις μετρήσεις μέχρι και τη μέτρηση  $\mathbf{y}(n-1)$ .

Όπως είναι εμφανές, το πρόβλημα μπορεί να χωριστεί σε 2 μικρότερα προβλήματα. Το πρώτο και ίσως το πιο σημαντικό είναι η επιτυχής εκτίμηση της τάξης  $\theta$  του εκτιμητή. Όταν αυτό επιτευχθεί είναι δυνατή η συνέχεια με την επίλυση του δεύτερου προβλήματος, το οποίο είναι ο υπολογισμός του συνόλου των συντελεστών  $\{A_i\}$  του γραμμικού εκτιμητή.

Η σωστή εκτίμηση της τάξης ενός *MV AR* μοντέλου αποτελεί ένα σοβαρό επιστημονικό πρόβλημα και η διερεύνησή του είναι κάτι που έχει απασχολήσει εκτεταμένα την επιστημονική κοινότητα τα τελευταία χρόνια. Θα μπορούσαμε να πούμε ότι πρόκειται για την επέκταση της βαθμωτής περίπτωσης για την οποία έχουν ήδη προταθεί αρκετές μέθοδοι και κριτήρια που έχουν δοκιμαστεί και εφαρμοστεί με επιτυχία. Αναφέρουμε ονομαστικά: [8], [19]-[27]

- *Akaike's Information Criterion (AIC)*
- *Schwarz's Bayesian Information Criterion (BIC)*
- *Rissanen's*
- *Wax's*
- *Hannan's & Quinn's (H & Q)*
- *Hurvich's & Tsai's (AICC) and*
- *Chen's, Davis', Brockwell's & Bai's order determination criteria (DC and MDC).*

Για να συμπληρωθεί η παραπάνω λίστα αναφέρεται και ένα ακόμα κριτήριο το οποίο παρουσιάστηκε πρόσφατα, (2003) από τους *Stijn de Waele και Piet M. T. Broersen* [28], και το οποίο βασίζεται στον υπολογισμό ενός συντελεστή ποινής (*penalty factor*) ο οποίος καθορίζεται από το αν η τάξη  $\theta$  του *MV AR* μοντέλου υπερεκτιμάται, (*overfit*) ή υποτιμάται (*underfit*).

Μερικά από τα προαναφερθέντα κριτήρια δεν είναι βέλτιστα για όλες τις περιπτώσεις και έχουν αποδειχθεί ότι κάποιες φορές είναι και ανεπαρκή. Μια εκτεταμένη μελέτη πάνω στο θέμα αυτό έχει ήδη γίνει το 1985 από τον *H. Lutkepohl*

[29]. Για παράδειγμα αναφέρουμε ότι το *Akaike's Information Criterion* συνήθως υπερεκτιμά την τάξη του μοντέλου (*overfit*). Επίσης, όλα τα κριτήρια αυτά βασίζουν την απόδοσή τους στην υπόθεση πως τα δεδομένα είναι *Gaussian* και σε ασυμπτωτικά αποτελέσματα. Επιπρόσθετα, για να λειτουργήσουν χρειάζονται μεγάλο όγκο αρχικών δεδομένων. Επίσης, είναι *two pass* μέθοδοι, δηλαδή απαιτείται η επεξεργασία των δεδομένων δυο φορές προκειμένου να εκτιμηθούν η τάξη και οι τελεστές του μοντέλου, με αποτέλεσμα να μην μπορούν να υλοποιηθούν *on line*.

Το πρόβλημα της ταυτόχρονης αναγνώρισης της τάξης και των τελεστών ενός *AR* μοντέλου επιλύθηκε αρχικά για τη βαθμωτή περίπτωση [30]. Στην περίπτωση των *MV AR* μοντέλων είτε παρουσιάστηκαν νέες μέθοδοι, όπως αυτή των *Neumaier και Schneider* [31], είτε τα ήδη υπάρχοντα κριτήρια και μέθοδοι μετασχηματίστηκαν ούτως ώστε να καλύπτουν και αυτήν την περίπτωση, όπως για παράδειγμα η επέκταση των κριτηρίων *AIC*, *BIC* και *H & Q* [32].

Στο κεφάλαιο αυτό παρουσιάζεται μια μέθοδος για ταυτόχρονη αναγνώριση των παραμέτρων και της τάξης χρονικά αμετάβλητων *MV AR* μοντέλων ως επέκταση της υπάρχουσας μεθόδου που λειτούργησε επιτυχώς για τη βαθμωτή περίπτωση [30]. Επίσης καταδεικνύεται ότι η μέθοδος μπορεί να χρησιμοποιηθεί με την ίδια επιτυχία και σε χρονικά μεταβαλλόμενα *MV AR* μοντέλα. Η συγκεκριμένη μέθοδος βασίζεται στην πολύ γνωστή θεωρία του *προσαρμοζόμενου πολυμοτελικού διαμελισμού (multi model partitioning theory)* [33]-[35] ή αλλιώς στα *φίλτρα Λαϊνιώτη*. Δεν περιορίζεται μόνο στην περίπτωση θορύβου *Gaussian*, μπορεί να χρησιμοποιηθεί *on line* και δεν απαιτεί μεγάλο υπολογιστικό φόρτο. Επίσης μπορεί να υπολογίσει τη σωστή τάξη του *MV AR* μοντέλου με μικρό αριθμό αρχικών δεδομένων.

## 1.2. Επαναδιατύπωση του προβλήματος

Ας υποθέσουμε αρχικά ότι η τάξη του μοντέλου  $\theta$  είναι γνωστή. Η εξίσωση (E-4) μπορεί να περιγραφεί από το ακόλουθο δυναμικό μοντέλο:

$$\mathbf{x}(k+1) = \mathbf{x}(k) \quad (1-3)$$

$$\mathbf{y}(k) = \mathbf{H}(k)\mathbf{x}(k) + \mathbf{v}(k) \quad (1-4)$$

όπου το διάνυσμα  $\mathbf{x}(k)$  έχει διάσταση  $m^2\theta \times 1$  και απαρτίζεται από όλους τους όρους των πινάκων  $\{\mathbf{A}_1, \dots, \mathbf{A}_\theta\}$ , και  $\mathbf{H}(k)$  είναι ένα δεύτερο διάνυσμα με διάσταση  $m \times m^2\theta$  το οποίο περιέχει το ιστορικό της ακολουθίας των μετρήσεων  $\{\mathbf{y}(k)\}$  έως και τη χρονική στιγμή  $k-\theta$ .

Σε αυτό το σημείο θα πρέπει να γίνουν κάποιες παρατηρήσεις:

1. Σε περίπτωση που οι εκτιμώμενοι συντελεστές υπόκεινται σε τυχαίες μεταβολές λόγω θορύβου οι εξισώσεις (1-3) και (1-4) γίνονται αντίστοιχα

$$\mathbf{y}(k) = \sum_{i=1}^{\theta} \mathbf{A}_i(k)\mathbf{y}(k-i) + \mathbf{v}(k) \quad (1-5)$$

$$\mathbf{x}(k+1) = \mathbf{x}(k) + \mathbf{w}(k) \quad (1-6)$$

Στην εξίσωση (1-5) ο πίνακας  $\mathbf{A}_i$  έχει αντικατασταθεί από άλλον πίνακα της μορφής  $\mathbf{A}_i(k)$  ώστε να αντικατοπτρίζεται το γεγονός ότι όλοι οι συντελεστές υπόκεινται σε τυχαίες μεταβολές λόγω θορύβου της μορφής:

$$\mathbf{A}_i(k+1) = \mathbf{A}_i(k) + \mathbf{W}, \quad i=1,2,\dots,\theta, \quad 0 \leq k \leq n \quad (1-7)$$

όπου  $\mathbf{v}(k)$ ,  $\mathbf{w}(k)$  είναι ανεξάρτητοι, λευκοί θόρυβοι, μηδενικής μέσης τιμής όχι απαραίτητα *Gaussian*

Υποθέτοντας ότι  $\mathbf{W} = \begin{bmatrix} w_{11}^\theta & \dots & w_{1m}^\theta \\ \vdots & \ddots & \vdots \\ w_{m1}^\theta & \dots & w_{mm}^\theta \end{bmatrix}$ , τότε μπορεί να οριστεί ένα διάνυσμα

θορύβου ως εξής:

$$\mathbf{w}(k) \triangleq [w_{11}^l \ w_{21}^l \ \dots \ w_{m1}^l \ ; \ w_{12}^l \ w_{22}^l \ \dots \ w_{m2}^l \ ; \ \dots \ w_{1m}^l \ ; \ \dots \ w_{mm}^l]^T$$

2. Μια πλήρης περιγραφή ενός συστήματος απαιτεί και τη γνώση των μητρών διασποράς  $\mathbf{Q}$  και  $\mathbf{R}$  των τυχαίων διεργασιών θορύβου  $\mathbf{w}(k)$  και  $\mathbf{v}(k)$  αντίστοιχα.

Υιοθετούμε την άποψη ότι οι διεργασίες αυτές είναι με τη ευρεία έννοια στάσιμες, συνεπώς και οι μήτρες  $\mathbf{Q}$  και  $\mathbf{R}$  θα είναι και αυτές με τη σειρά τους χρονικά αμετάβλητες. Η γνώση όμως των τιμών αυτών δεν είναι πάντα εύκολη υπόθεση. Εάν δεν είναι δεδομένες μπορούν να υπολογιστούν με διάφορες μεθόδους όπως για παράδειγμα αυτή που περιγράφεται από τους *P. Sage και G. W. Husa* [36]. Σε περίπτωση που οι συντελεστές είναι χρονικά αμετάβλητοι ή μεταβάλλονται πολύ αργά, η τιμή της μήτρας διασποράς  $\mathbf{Q}$  θεωρείται μηδέν (όπως στην περίπτωση που εξετάζουμε εδώ).

3. Επίσης είναι απαραίτητη η *a priori* (εκ των προτέρων) γνώση της μέσης τιμής και της διασποράς για κάθε έναν από τους τελεστές  $\{\mathbf{A}_i\}$ . Στη συνηθέστερη περίπτωση όπου δεν υπάρχει κάποια γνώση εκ των προτέρων σχετικά με τις μετρήσεις τότε ως *a priori* μέση τιμή όλων των  $\mathbf{A}_i(0)$  μπορεί να οριστεί το μηδέν. Όσον αφορά την αρχική τιμή της διασποράς των τελεστών  $\mathbf{A}_i$  αυτή συμβολίζεται ως  $\mathbf{P}_0$  όπου  $\mathbf{P}_0 = n\mathbf{I}$ , με  $n$  κάποιον ακέραιο.

Ας υποθέσουμε τώρα την περίπτωση όπου δεν είναι γνωστές όλες οι παράμετροι του συστήματος. Στην περίπτωση αυτή το *αυτοπροσαρμοζόμενο φίλτρο πολυμοντελικού διαμελισμού*, (multimodel partitioning filter - MMPF) ή *φίλτρο Λαϊνιώτη* είναι αυτό που χρησιμοποιείται περισσότερο. Αυτή η προσέγγιση προτάθηκε από τον *Δ. Γ. Λαϊνιώτη*, [33]-[35], και συγκεντρώνει όλη την παραμετρική αβεβαιότητα του μοντέλου σε ένα άγνωστο, πεπερασμένης διάστασης διάνυσμα του οποίου οι τιμές μπορούν να αναζητηθούν ανάμεσα από ένα άλλο γνωστό σύνολο πεπερασμένου πληθικού αριθμού (*finite cardinality*). Με την πάροδο των χρόνων η θεωρία πολυμοντελικού διαμελισμού Λαϊνιώτη έχει δώσει πληθώρα αλγορίθμων, οι οποίοι έχουν εφαρμοστεί με επιτυχία σε εφαρμογές όπως εντοπισμός στόχου και θέσης [37]-[38], [47], ανίχνευση πολλαπλών πηγών σημάτων [39], ανίχνευση δικτυακών ανωμαλιών [40], εκτίμηση του εναπομείναντα χρόνου ζωής κατασκευών, [41], επεξεργασία σημάτων lidar [42], επεξεργασία σημάτων sonar [43]-[45], επεξεργασία γεωφυσικών σημάτων [46], αναγνώριση μη γραμμι-

κών συστημάτων με παραμετρική αβεβαιότητα [48], ενώ έχει συνδυαστεί επιτυχώς και με γενετικούς αλγορίθμους [49], [92].

Στο πρόβλημα που εξετάζουμε σ' αυτήν την ενότητα θεωρούμε ότι υπάρχει παραμετρική αβεβαιότητα, η οποία εντοπίζεται στην άγνοια της τάξης  $\theta$  του μοντέλου. Επίσης θεωρούμε ότι η τιμή της παραμέτρου  $\theta$  βρίσκεται μέσα σε γνωστό διακριτό δειγματικό χώρο  $\mathcal{T}$  έτσι ώστε  $1 \leq \theta \leq M$ ,  $\theta \in \mathcal{T}$ , όπου  $\mathcal{T}$ , υποδηλώνει το σύνολο των ακέραιων αριθμών.

Το φίλτρο Λαϊνιώτη ή φίλτρο πολυμοντελικού διαμελισμού (MMPF), λειτουργεί με βάση το ακόλουθο δυναμικό μοντέλο:

$$\mathbf{x}(k+1) = \mathbf{F}(k+1, k / \theta) \mathbf{x}(k) + \mathbf{w}(k) \quad (1-8)$$

$$\mathbf{y}(k) = \mathbf{H}(k / \theta) \mathbf{x}(k) + \mathbf{v}(k) \quad (1-9)$$

όπου το διάνυσμα  $\theta$  συνοψίζει την παραμετρική αβεβαιότητα του συστήματος, δηλαδή την τάξη του μοντέλου. Σχηματικά το φίλτρο Λαϊνιώτη, *MMPF*, μπορεί να αναπαρασταθεί ως εξής:

$$\text{Έστω ότι η γενική μορφή κάθε πίνακα } \mathbf{A}_\theta \text{ είναι } \begin{bmatrix} a_{11}^\theta & \dots & a_{1m}^\theta \\ \vdots & \ddots & \vdots \\ a_{m1}^\theta & \dots & a_{mm}^\theta \end{bmatrix}. \text{ Τότε μπορού-}$$

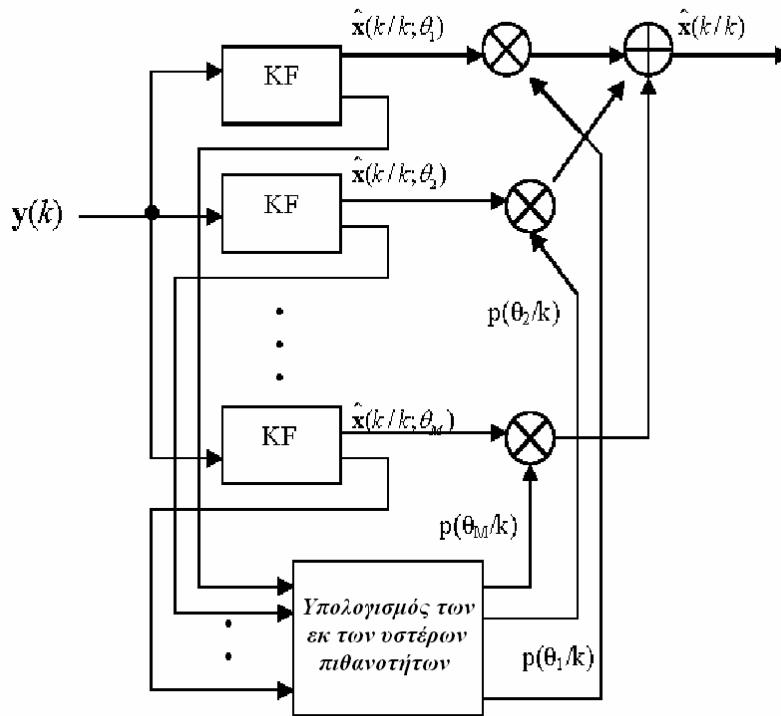
με να γράψουμε τα διανύσματα  $\mathbf{x}(k)$  και  $\mathbf{H}(k)$  ως εξής:

$$\mathbf{x}(k) \triangleq [\alpha_{11}^1 \alpha_{21}^1 \dots \alpha_{m1}^1 : \alpha_{12}^1 \alpha_{22}^1 \dots \alpha_{m2}^1 : \dots : \alpha_{1m}^1 \alpha_{2m}^1 \dots \alpha_{mm}^1]^T$$

$$\mathbf{H}(k) \triangleq [y_1(k-1)I \dots y_m(k-1)I : \dots : y_1(k-\theta)I \dots y_m(k-\theta)I]$$

όπου  $\mathbf{I}$  είναι ταυτοτικός πίνακας διαστάσεων  $m \times m$  και  $\theta$  η τάξη του μοντέλου.

Στην περίπτωση που γνωρίζαμε τόσο το μοντέλο του συστήματος όσο και τις στατιστικές παραμέτρους του, το *Φίλτρο Kalman* στις διάφορες μορφές του θα ήταν ο βέλτιστος γραμμικός εκτιμητής (με την έννοια του ελάχιστου μέσου τετραγωνικού λάθους *minimum mean square error - MMSE*).



Εικ. 1-1. Σχηματικό διάγραμμα φίλτρου Λαϊνιώτη (MMPF)

Στην περίπτωση που ο θόρυβος είναι Gaussian και δεδομένης της ακολουθίας των μετρήσεων  $\mathbf{Y}_k = \{ y(1), \dots, y(k) \}$  ο βέλτιστος εκτιμητής  $\hat{\mathbf{x}}(k/k)$  (με την έννοια του ελάχιστου μέσου τετραγωνικού λάθους (MMSE)) της κατάστασης  $\mathbf{x}(k)$  και η αντίστοιχη διασπορά λάθους  $\mathbf{P}(k/k)$  δίνεται από τις ακόλουθες σχέσεις [23]:

$$\hat{\mathbf{x}}(k/k) = \sum_{j=1}^M \hat{\mathbf{x}}(k/k; \theta_j) p(\theta_j/k) \quad (1-10)$$

$$\mathbf{P}(k/k) = \sum_{j=1}^M \left[ \mathbf{P}_j(k/k; \theta) + \left\| \hat{\mathbf{x}}(k/k) - \hat{\mathbf{x}}(k/k; \theta) \right\|^2 \right] p(\theta_j/k) \quad (1-11)$$

όπου  $\hat{\mathbf{x}}(k/k; \theta)$  η βέλτιστη (MMSE) εκτίμηση της κατάστασης δεδομένης της παραμέτρου  $\theta$ , και  $\mathbf{P}(k/k; \theta)$  η αντίστοιχη μήτρα διασποράς του λάθους, που ορίζονται ως εξής:

$$\hat{\mathbf{x}}(k/k; \theta) = E \{ \mathbf{x}(k) / y_k; \theta \} \quad (1-12)$$

$$\mathbf{P}(k/k;\theta) = E \left\{ \left\| \hat{\mathbf{x}}(k/k) - \hat{\mathbf{x}}_i(k/k;\theta) \right\|^2 / y_k; \theta \right\} \quad (1-13)$$

Τα μεγέθη αυτά προέρχονται από ένα γραμμικό φίλτρο (Kalman ή Λαϊνιώτη), το οποίο υλοποιείται για κάποια συγκεκριμένη τιμή της  $\theta$  και αρχικοποιείται με  $\hat{\mathbf{x}}(0/0;\theta)$  και  $\mathbf{P}(0/0;\theta)$  αντίστοιχα [50].

Η εκ των υστέρων κατανομή  $p(\theta/k)$  της  $\theta$  δεδομένων των μετρήσεων  $\mathbf{Y}_k$  υπολογίζεται *on line* από την ακόλουθη αναδρομική σχέση τύπου Bayes:

$$p(\theta_j/k) = \frac{L(k/k;\theta_j)}{\sum_{j=1}^M L(k/k;\theta_j)} p(\theta_j/k-1) \quad (1-14)$$

όπου η συνάρτηση πιθανοφάνειας  $L(k/k;\theta)$  δίνεται από τη σχέση:

$$L(k/k;\theta_j) = \left| \mathbf{P}_{\tilde{\mathbf{y}}}(k/k-1;\theta_j) \right|^{-1/2} \cdot \exp \left[ -\frac{1}{2} \tilde{\mathbf{y}}^T(k/k-1;\theta_j) \mathbf{P}_{\tilde{\mathbf{y}}}^{-1}(k/k-1;\theta_j) \tilde{\mathbf{y}}(k/k-1;\theta_j) \right] \quad (1-15)$$

και όπου η διαδικασία ανανέωσης δεδομένου του  $\theta$  είναι διαδικασία λευκού θορύβου, (μηδενικής μέσης τιμής), που ορίζεται ως εξής:

$$\tilde{\mathbf{y}}(k/k-1;\theta_j) = \mathbf{y}(k) - \mathbf{H}(k;\theta_j) \hat{\mathbf{x}}(k/k-1;\theta_j) \quad (1-16)$$

με μήτρα διασποράς δεδομένου του  $\theta$

$$\mathbf{P}_{\tilde{\mathbf{y}}}(k/k-1;\theta_j) = \mathbf{H}(k;\theta_j) \mathbf{P}(k/k;\theta_j) \mathbf{H}^T(k;\theta_j) + \mathbf{R} \quad (1-17)$$

Για τις εξισώσεις από (1-14) – (1-17) ισχύει ότι  $j = 1, 2, \dots, M$ .

Παρατηρήσεις:

4. Η βέλτιστη εκτίμηση  $\hat{\mathbf{x}}(k/k)$  της κατάστασης  $\mathbf{x}(k)$  δίνεται ως άθροισμα, με συντελεστές βαρύτητας, των  $\hat{\mathbf{x}}(k/k;\theta)$ . Οι εκτιμήσεις αυτές προέρχονται από μια ομάδα στοιχειωδών γραμμικών φίλτρων, ένα για κάθε πιθανή τιμή της  $\theta$ , (με την έννοια ότι  $p(\theta) \neq 0$  για την τιμή αυτή). Τα στοιχειώδη φίλτρα είναι εντελώς ανεξάρτητα μεταξύ τους, πράγμα που επιτρέπει την παράλληλη υλοποίηση τους εξοικονομώντας έτσι πολύτιμο υπολογιστικό χρόνο.



5. Το παραπάνω πρόβλημα αυτο-προσαρμοζόμενης εκτίμησης μπορεί να θεωρηθεί ως συνδυασμός εκτίμησης, όσον αφορά το  $\mathbf{x}(k)$  και ελέγχου υποθέσεων, όσον αφορά την απόφαση για το ποιο μοντέλο (ή ισοδύναμα ποια τιμή της  $\theta$ ) έχει παράγει το σύνολο των μετρήσεων  $\mathbf{Y}_k$  [33].
6. Ο αλγόριθμος παρέχει ακριβή έκφραση για τη διασπορά του λάθους εκτίμησης  $\mathbf{P}(k/k)$  μέσω της (1-13). Ο υπολογισμός της διασποράς χρησιμοποιεί μεγέθη που είναι ούτως ή άλλως διαθέσιμα και επομένως έχει ελάχιστες επί πλέον υπολογιστικές απαιτήσεις. Η μήτρα  $\mathbf{P}(k/k)$  είναι χρήσιμη για την αξιολόγηση της συμπεριφοράς του αλγορίθμου και τη σύγκρισή του με υποβέλτιστες υλοποιήσεις. Ο όρος  $\|\hat{\mathbf{x}}(k/k) - \hat{\mathbf{x}}_i(k/k; \theta)\|^2$  δίνει ένα μέτρο για την υποβάθμιση της απόδοσης που προκύπτει από τη χρήση του αυτο-προσαρμοζόμενου αλγορίθμου σε ένα πλήρως γνωστό μοντέλο αντί της χρήσης ενός απλού γραμμικού φίλτρου. Δηλαδή ο όρος αυτός εκφράζει το επί πλέον μέσο τετραγωνικό λάθος της αβεβαιότητας του μοντέλου.
7. Ο αλγόριθμος που παρουσιάζεται εδώ υπολογίζει τη βέλτιστη εκτίμηση  $\hat{\mathbf{x}}(k/k)$  της  $\mathbf{x}(k)$  με την έννοια ότι η  $\hat{\mathbf{x}}(k/k)$  παρουσιάζει το ελάχιστο μέσο τετραγωνικό λάθος (MMSE). Ένα άλλο κριτήριο βελτιστότητας που χρησιμοποιείται στην πράξη είναι η μεγιστοποίηση της εκ των υστέρων πιθανότητας (*maximum a posteriori probability* - MAP) [50]-[51]. Με βάση αυτό το κριτήριο η εκτίμηση  $\hat{\theta}_{MAP}$  της παραμέτρου είναι η πιθανότερη τιμή της  $\theta$  δεδομένων των μετρήσεων, δηλαδή αυτή που μεγιστοποιεί την  $p(\theta/k)$ . Η βέλτιστη εκτίμηση της κατάστασης είναι απλά η έξοδος του στοιχειώδους φίλτρου που αντιστοιχεί στη  $\hat{\theta}_{MAP}$ :  $\hat{\mathbf{x}}_{MAP}(k/k) = \hat{\mathbf{x}}(k/k; \hat{\theta}_{MAP})$ . Ο υπολογισμός της εκτίμησης MAP είναι απλούστερος από αυτόν της εκτίμησης MMSE, πράγμα που δικαιολογεί τη χρήση αυτού του κριτηρίου στα παραδείγματα του κεφαλαίου αυτού.
8. Ένα πολύ σημαντικό χαρακτηριστικό του αλγορίθμου είναι ότι συγκλίνει στην πραγματική τιμή της παραμέτρου, όταν αυτή βρίσκεται εντός του δειγματικού χώρου, τον οποίο υποθέτει ο εκτιμητής. Το γεγονός αυτό έχει αποδειχθεί

αναλυτικά [52]-[53], και έχει επιβεβαιωθεί πειραματικά. Στην περίπτωση που εξετάζεται εδώ, εάν η αληθινή τιμή της τάξης του μοντέλου  $\theta$ , είναι μικρότερη από  $M$ , δηλαδή συμπεριλαμβάνεται στον δειγματικό χώρο, η εκ των υστέρων πιθανότητα που αντιστοιχεί σε αυτό το μοντέλο θα τείνει στη μονάδα και οι εναπομείνουσες εκ των υστέρων πιθανότητες θα τείνουν στο μηδέν. Αυτό το αποτέλεσμα ισχύει με την προϋπόθεση ότι η διεργασία  $\tilde{y}(k/k - 1)$  είναι στάσιμη με την ευρεία έννοια. Αυτό με τη σειρά του προϋποθέτει ότι το MV AR μοντέλο τάξεως  $\theta$  θα είναι και αυτό στάσιμο.

**9.** Στην περίπτωση που η πραγματική τιμή του μοντέλου  $\theta$  βρίσκεται εκτός του δειγματικού χώρου, είτε λόγω διακριτοποίησης, είτε λόγω εσφαλμένης μοντελοποίησης, ο αλγόριθμος συγκλίνει στην «πλησιέστερη» από τις υποτιθέμενες τιμές της  $\theta$  με την έννοια της ελαχιστοποίησης του μέτρου πληροφορίας Kullback [52]. Έτσι λοιπόν εάν τα δεδομένα προέρχονται από ένα μοντέλο το οποίο ουσιαστικά δεν είναι αληθινά *MV AR*, ο αλγόριθμος θα επιλέξει ως λύση ένα από τα  $M$  προτεινόμενα μοντέλα του οποίου η συμπεριφορά θα είναι «πλησιέστερη» (με την έννοια της ελαχιστοποίησης του μέτρου πληροφορίας Kullback) στα δεδομένα αυτά.

**10.** Στην περίπτωση που εξετάζεται εδώ, η παραμετρική αβεβαιότητα  $\theta$  ανήκει σε διακριτό (*discrete*) δειγματικό χώρο. Εάν όμως η  $\theta$  είναι συνεχής, η υλοποίηση του βέλτιστου εκτιμητή απαιτεί μη αριθμήσιμη απειρία στοιχειωδών φίλτρων, καθώς και τον υπολογισμό και αποθήκευση, σε πραγματικό χρόνο, της συνεχούς κατανομής  $p(\theta / k)$ . Η συνήθης προσέγγιση για να αντιμετωπιστεί αυτή η δυσκολία είναι η διακριτοποίηση του δειγματικού χώρου  $\mathcal{I}$ , δηλαδή η προσέγγιση της  $p(\theta / k)$  από ένα πεπερασμένο άθροισμα. Η επιλογή του επιπέδου διακριτοποίησης αποτελεί ένα συμβιβασμό μεταξύ της ακρίβειας του αλγόριθμου και του αριθμού των στοιχειωδών φίλτρων, δηλαδή του υπολογιστικού φόρτου. Για παράδειγμα, ένα  $m$ -διάστατο  $\theta$  με  $q$  επίπεδα διακριτοποίησης ανά παράμετρο απαιτεί υλοποίηση  $q^m$  στοιχειωδών φίλτρων [54]. Ορισμένες τεχνικές προτείνουν αλλαγή του σχήματος διακριτοποίησης είτε περιοδικά, είτε

όταν κάποια από τις εκ των υστέρων πιθανότητες  $p(\theta / k)$  περάσει κάποιο προκαθορισμένο όριο. Από αυτές ιδιαίτερα αποδοτική είναι η μέθοδος δυαδικής διακριτοποίησης (*binary quantization*) [55], η οποία χρησιμοποιεί μόνο δυο επίπεδα και επομένως είναι η απλούστερη υλοποίηση του βέλτιστου εκτιμητή.

**11.** Η αρχικοποίηση των παραμέτρων του φίλτρου Λαϊνιώτη (MMPF) γίνεται ως εξής:

$$\hat{\mathbf{x}}(0/0; \theta_j) = [1 \quad 1 \quad 1 \quad \dots \quad 1]^T, \text{ η διάσταση του διανύσματος είναι } m^2 j \times 1,$$

$$\mathbf{P}(0/0; \theta_j) = \begin{bmatrix} 10 & 0 & \dots & 0 \\ 0 & 10 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & 10 \end{bmatrix}, \text{ διαγώνιος πίνακας με διάσταση } m^2 j \times m^2 j$$

και

$$p(\theta_j/k) = 1/M, \text{ όπου } j = 1, 2, \dots, M.$$

### 1.3. Παρουσίαση των συγκρινόμενων κριτηρίων.

Η πλειοψηφία των κλασικών μεθόδων και κριτηρίων επιλογής της τάξης ενός MV AR μοντέλου βασίζονται στην ελαχιστοποίηση μιας *αντικειμενικής* συνάρτησης (*objective function*) της μορφής:

$$\delta(k) = \ln \left( \left| \hat{\mathbf{R}}_k \right| \right) + C_n k, \quad (1-18)$$

όπου  $n$  είναι το μέγεθος του δείγματος,  $C_n$  είναι ο «*συντελεστής ποινής*» (*penalty factor*) δηλαδή μια σειρά προκαθορισμένων σταθερών όρων,  $k$  είναι η τάξη του μοντέλου και  $\hat{\mathbf{R}}_k$  η εκτίμηση μέγιστης πιθανοφάνειας (*maximum likelihood estimate*) της μήτρας διασποράς  $\mathbf{R}$ , υπό την προϋπόθεση πως η τιμή  $k$  είναι η αληθινή τάξη του μοντέλου  $AR(k)$  [32].

Σε αυτήν την ενότητα ο προτεινόμενος αλγόριθμος που στηρίζεται στη θεωρία του πολύ-μοντελικού διαμελισμού συγκρίνεται με τα ακόλουθα κριτήρια

$$AIC \quad \log\left(\left|\widehat{\mathbf{R}}_k\right|\right) + \frac{2km^2}{n} \quad (1-19)$$

$$AICC \quad \log\left(\left|\widehat{\mathbf{R}}_k\right|\right) + \frac{2(km^2 + 1)}{n - (km^2 + 2)} \quad (1-20)$$

$$H \& Q \quad \log\left(\left|\widehat{\mathbf{R}}_k\right|\right) + \frac{(2 \log \log n)km^2}{n} \quad (1-21)$$

$$BIC \quad n \log\left(\left|\widehat{\mathbf{R}}_k\right|\right) + m + \left(m^2k + m\left(\frac{m+1}{2}\right)\right) \log n \quad (1-22)$$

και  $DC$  και  $MDC$ , δυο πρόσφατα κριτήρια που εφαρμόζουν μια νέα μέθοδο δειγματοληψίας με στόχο την εκτίμηση καλύτερων «συντελεστών ποινής» (*penalty factor*)  $C_n$  [27], [32].

Τα κριτήρια ( 1-21 ) και ( 1-22 ) είναι ευρέως δοκιμασμένα με επιτυχία στην επιλογή της τάξης μοντέλων  $MV AR$  με την έννοια ότι η συνάρτηση  $\delta(k)$  συγκλίνει στην αληθινή τιμή της άγνωστης παραμέτρου  $\theta$ , με πιθανότητα ένα, ιδιότητα που δεν την έχουν τα κριτήρια  $AIC$  και  $AICC$ . Τα δυο αυτά κριτήρια σχεδιάστηκαν ώστε να είναι μη πολωμένοι εκτιμητές (*unbiased estimators*) του δείκτη Kullback-Leibler [25], όταν η διεργασία είναι Gaussian, και είναι ασυμπτωτικά αποδοτικοί [56]. Όλα όμως ( 1-19 )–( 1-22 ), έχουν το μειονέκτημα ότι ο συντελεστής ποινής  $C_n$  αγνοεί ενδεχόμενα σημαντικές πληροφορίες οι οποίες περιέχονται στα δεδομένα. Τα δυο τελευταία κριτήρια  $DC$ ,  $MDC$  αντιπαρέρχονται τις αδυναμίες των υπολοίπων κριτηρίων προτείνοντας μια μέθοδο επαναληπτικής δειγματοληψίας (*resampling method*), βάση της οποίας προκύπτει μια σειρά συντελεστών ποινής  $C_n$  που ταιριάζουν καλύτερα στα δεδομένα. Το μειονέκτημά τους είναι πως λόγω της επαναληπτικής δειγματοληψίας δημιουργείται επιπλέον υπολογιστικός φόρτος. Για παράδειγμα δουλεύοντας σε SPARC IPC, με βαθμωτό μοντέλο  $AR$  και για 100 αρχικές μετρήσεις οι μέθοδοι  $DC$  και  $MDC$  απαιτούν 1.31’’ και 1.28’’ αντίστοιχα ενώ το κριτήριο  $AIC$  χρειάζεται μόλις 0.1’’ ώστε να εκτιμήσει τη σωστή τάξη του μοντέλου [27, 32].

Εδώ θα πρέπει να σημειώσουμε πως το κριτήριο ( 1-20 )  $AICC$  (*corrected Akaike*) είναι διαφορετικό από το  $AICc$  όπως το τελευταίο έχει οριστεί από τους

Hurvich και Tsai [26]. Επειδή όμως σε συγκριτική έρευνα, [26] το *AICC* είχε σημαντικά καλύτερη απόδοση από το *AICc*, με βάση πάντα την επιτυχή εκτίμηση της τάξης του μοντέλου  $\theta$ , γι' αυτό και χρησιμοποιείται σε αυτήν την μελέτη. Πληροφοριακά αναφέρεται ότι

$$AICc = \log\left(\left|\widehat{\mathbf{R}}_k\right|\right) + \frac{2(km^2 + m(m+1)/2)}{n - (km + m + 1)} \quad (1-23)$$

Για την αξιολόγηση του προτεινόμενου αλγορίθμου και τη σύγκρισή του με τα προαναφερθέντα κριτήρια της βιβλιογραφίας, εκτελέστηκαν πειράματα εξομοίωσης με κοινά μοντέλα και ίδιες παραμέτρους ώστε να μπορεί να γίνει σύγκριση. Το κάθε ένα από τα πειράματα εξομοίωσης επαναλήφθηκε 100 φορές (100 *Monte Carlo Runs-MCRs*) για κάθε σύνολο αρχικών δεδομένων. Το μοντέλο που χρησιμοποιήθηκε ήταν της μορφής (1-3) και (1-4). Τα μοντέλα των παραδειγμάτων 1-3 βρέθηκαν από το [32].

#### 1.4. Παραδείγματα και αποτελέσματα

**Παράδειγμα 1<sup>ο</sup>:** Μοντέλο MV AR 1<sup>ης</sup> τάξης με στοιχεία

$$\mathbf{y}_k = \sum_{i=1}^1 \mathbf{A}_i \mathbf{y}_{k-i} + \mathbf{v}_k, \quad \mathbf{A}_1 = \begin{bmatrix} -1.0 & 0.96 \\ -1.5 & 1.4 \end{bmatrix}, \quad (1-24)$$

$$\text{μήτρα διασποράς } \mathbf{R} = \begin{bmatrix} 1.0 & -0.08 \\ -0.08 & 1.0 \end{bmatrix} \text{ και } M=10.$$

Στον Πίνακα 1-1 συνοψίζονται τα αποτελέσματα της συγκριτικής εξομοίωσης. Τα εκτιμώμενα στοιχεία των τελεστών  $\{\mathbf{A}_i\}$  του μοντέλου καθώς και η τετραγωνική ρίζα του αντίστοιχου Μέσου Τετραγωνικού Λάθους (*root mean square error – RMS Error*) συνοψίζονται στον Πίνακα 1-2. Η Εικόνα 1-2 απεικονίζει την ακολουθία των εκ των υστέρων πιθανοτήτων που αντιστοιχούν σε κάθε μια από τις προτεινόμενες τιμές του  $\theta$ .

Όπως προκύπτει από τον Πίνακα 1-1, τόσο ο προτεινόμενος αλγόριθμος *MMPF* όσο και το κριτήριο *MDC*, είναι 100% επιτυχή, (δηλαδή και για τα 100 *MCRs*

εκτίμησαν τη σωστή τάξη του μοντέλου, εδώ  $\theta = 1$ ) και για τα δυο σύνολα αρχικών δεδομένων, (το μικρότερο των 50, αλλά και για το μεγαλύτερο των 100).

Οι υπόλοιπες μέθοδοι παρουσιάζουν σχεδόν την ίδια απόδοση συγκρινόμενες μεταξύ τους. Είναι εμφανές πως το *AIC*, υπερεκτιμά (*overfit*) την τάξη του μοντέλου περισσότερο από οποιοδήποτε άλλο κριτήριο που παρουσιάζεται.

Εκτίμηση της τάξης $\theta$						
Κριτήριο	$\theta$	1	2	3	4	5-10
<i>AIC</i>	0 (0)	96 (88)	0 (8)	4 (2)	0 (2)	0 (0)
<i>AICC</i>	0 (0)	98 (96)	0 (4)	2 (0)	0 (0)	0 (0)
<i>H &amp; Q</i>	0 (0)	98 (98)	0 (2)	2 (0)	0 (0)	0 (0)
<i>BIC</i>	0 (0)	99 (100)	1 (0)	0 (0)	0 (0)	0 (0)
<i>DC</i>	0 (0)	100 (97)	0 (1)	0 (1)	0 (1)	0 (0)
<i>MDC</i>	0 (0)	100 (100)	0 (0)	0 (0)	0 (0)	0 (0)
<i>MMPF</i>	0 (0)	100 (100)	0 (0)	0 (0)	0 (0)	0 (0)

Πίνακας 1-1. Παράδειγμα 1<sup>0</sup>: Συχνότητα της εκτιμώμενης τάξης  $\theta$  σε 100 *MCRs* με αρχικά δεδομένα 50 και 100 (σε παρένθεση).

Πραγματικοί Τελεστές	Εκτιμώμενοι Τελεστές	$\sqrt{\text{Μέσο Λάθος}}$
-1.0000	-1.0001	0.0988
-1.5000	-1.4949	0.1218
0.9600	0.9759	0.1042
1.4000	1.3773	0.0939


Πίνακας 1-2. Παράδειγμα 1<sup>0</sup>: Πραγματικοί και Εκτιμώμενοι Τελεστές και η Τετραγωνική ρίζα του αντίστοιχου Μέσου Τετραγωνικού Λάθους (*Root Mean Square Error*)

Η Εικόνα 1-2 απεικονίζει την ακολουθία των εκ των υστέρων πιθανοτήτων του φίλτρου Λαϊνιώτη, *MMPF*. Όπως είναι εμφανές το φίλτρο συγκλίνει πολύ γρήγορα στη σωστή τάξη του μοντέλου,  $\theta = 1$ , σε τρία μόνο βήματα. Ως κριτήριο σύγκλισης θεωρείται κάποια από τις εκ των υστέρων πιθανότητες να έχει τιμή μεγαλύτερη από 0.9.

### Παρατήρηση:

Ο οριζόντιος άξονας ξεκινά από την  $10^{\text{η}}$  χρονική στιγμή και όχι από το μηδέν. Αυτό συμβαίνει διότι η αρχική υπόθεση ήταν πως η άγνωστη τάξη του μοντέλου βρίσκεται στο διακριτό διάστημα  $[1, M]$ , όπου  $M = 10$ . Συνεπώς τα πρώτα 10 δείγματα των αρχικών δεδομένων χρησιμοποιούνται για την αρχικοποίηση του αλγορίθμου. Το ίδιο ισχύει και για τα υπόλοιπα παραδείγματα που ακολουθούν.

Εικ. 1-2. Παράδειγμα 1°. Ακολουθία των εκ των υστέρων πιθανοτήτων φίλτρου Λαϊνιώτη (MMPF)



**Παράδειγμα 2°:** Μοντέλο MV AR 2<sup>ης</sup> τάξης με στοιχεία:

$$\mathbf{y}_k = \sum_{i=1}^2 \mathbf{A}_i \mathbf{y}_{k-i} + \mathbf{v}_k, \quad \mathbf{A}_1 = \begin{bmatrix} 0.5 & -0.3 \\ 0.2 & 0.65 \end{bmatrix}, \mathbf{A}_2 = \begin{bmatrix} -0.5 & 0.3 \\ 0.0 & -0.4 \end{bmatrix} \quad (1-25)$$

μήτρα διασποράς  $\mathbf{R} = \begin{bmatrix} 1.0 & -0.08 \\ -0.08 & 1.0 \end{bmatrix}$  και  $M=10$ .

Ο Πίνακας 1-3 συγκεντρώνει τα αποτελέσματα της εξομοίωσης και ο Πίνακας 1-4 τα εκτιμώμενα στοιχεία των τελεστών  $\{A_i\}$  του μοντέλου καθώς και την τετραγωνική ρίζα του αντίστοιχου Μέσου Τετραγωνικού Λάθους (*RMS Error*). Η Εικόνα 1-3 απεικονίζει την ακολουθία των εκ των υστέρων πιθανοτήτων που αντιστοιχούν σε κάθε μια από τις προτεινόμενες τιμές του  $\theta$ .

Εκτίμηση της τάξης $\theta$						
Κριτήριο	$\theta$	1	2	3	4	5-10
<i>AIC</i>	0 (0)	0 (0)	89 (88)	7 (11)	2 (0)	2 (1)
<i>AICC</i>	0 (0)	2 (0)	98 (95)	0 (5)	0 (0)	0 (0)
<i>H &amp; Q</i>	0 (0)	2 (0)	96 (99)	2 (1)	0 (0)	0 (0)
<i>BIC</i>	0 (0)	4 (0)	96 (100)	0 (0)	0 (0)	0 (0)
<i>DC</i>	0 (0)	1 (0)	97 (99)	2 (1)	0 (0)	0 (0)
<i>MDC</i>	0 (0)	6 (0)	94 (100)	0 (0)	0 (0)	0 (0)
<i>MMPF</i>	0 (0)	0 (0)	100 (100)	0 (0)	0 (0)	0 (0)

Πίνακας 1-3. Παράδειγμα 2<sup>0</sup>: Συχνότητα της εκτιμώμενης τάξης  $\theta$  σε 100 *MCRs* με αρχικά δεδομένα 50 και 100 (σε παρένθεση).

Πραγματικοί Τελεστές		Εκτιμώμενοι Τελεστές		$\sqrt{\text{Μέσο Λάθος}}$	
0.5000	-0.5000	0.5011	-0.4861	0.1052	0.0982
0.2000	0	0.2034	0.0144	0.0854	0.0900
-0.3000	0.3000	-0.2905	0.3094	0.1623	0.1541
0.6500	-0.4000	0.6273	-0.3540	0.1333	0.1285


Πίνακας 1-4. Παράδειγμα 2<sup>0</sup>: Πραγματικοί και Εκτιμώμενοι Τελεστές και η Τετραγωνική ρίζα του αντίστοιχου Μέσου Τετραγωνικού Λάθους (*Root Mean Square Error*).

Όπως διαπιστώνουμε, το φίλτρο Λαϊνιώτη, *MMPF*, είναι για άλλη μια φορά αλάνθαστο και για τα δυο σύνολα αρχικών δεδομένων. Συγκλίνει και πάλι στη σωστή τάξη του μοντέλου,  $\theta = 2$ , πολύ γρήγορα, σε πέντε μόλις βήματα, όπως φαίνεται και από την Εικόνα 1-3. Ως κριτήριο σύγκλισης θεωρείται κάποια από τις εκ των υστέρων πιθανότητες να έχει τιμή μεγαλύτερη από 0.9.



Από τον Πίνακα 1-3 μπορούμε να διαπιστώσουμε πως τα κριτήρια *BIC* και *MDC* είναι και αυτά 100% επιτυχή μόνο όμως όταν έχουν στη διάθεσή τους το μεγαλύτερο σύνολο αρχικών δεδομένων.

Εικ. 1-3. Παράδειγμα 2°. Ακολουθία των εκ των υστέρων πιθανοτήτων φίλτρου Λαϊνιώτη (*MMPF*)



**Παράδειγμα 3°:** Μοντέλο MV AR 3<sup>ης</sup> τάξης με στοιχεία:

$$y_k = \sum_{i=1}^3 A_i y_{k-i} + v_k, \quad A_1 = \begin{bmatrix} -0.17 & 0.14 \\ -0.19 & -0.1 \end{bmatrix}, \quad A_2 = \begin{bmatrix} -0.2 & 0.12 \\ 0.22 & -0.25 \end{bmatrix}, \quad A_3 = \begin{bmatrix} 0.0 & 0.4 \\ 0.15 & -0.37 \end{bmatrix} \quad (1-26)$$

μήτρα διασποράς  $\mathbf{R} = \begin{bmatrix} 1.0 & -0.08 \\ -0.08 & 1.0 \end{bmatrix}$  και  $M=10$ .

Ο Πίνακας 1-5 μας δείχνει πως όσο η τάξη του μοντέλου αυξάνει, άρα και η πολυπλοκότητά του, όλες οι εξεταζόμενες μέθοδοι, εκτός του φίλτρου Λαϊνιώτη *MMPF*, χρειάζονται όλο και μεγαλύτερο σύνολο αρχικών δεδομένων προκειμένου να εκτιμήσουν με επιτυχία την τάξη του μοντέλου. Το φίλτρο Λαϊνιώτη

*MMPF*, είναι 100% επιτυχής για όλα τα σύνολα αρχικών δεδομένων. Σε αυτή την εξομοίωση χρησιμοποιούνται τρία σύνολα αρχικών δεδομένων: ένα μικρό των 50 δειγμάτων, ένα μεσαίο των 100 δειγμάτων και ένα μεγαλύτερο των 200 δειγμάτων.

Ο Πίνακας 1-6 παρουσιάζει τα εκτιμώμενα στοιχεία των τελεστών  $\{A_i\}$  του μοντέλου καθώς και την τετραγωνική ρίζα του αντίστοιχου Μέσου Τετραγωνικού Λάθους (*root mean square error – RMS Error*).

Η Εικόνα 1-4 απεικονίζει την ακολουθία των εκ των υστέρων πιθανοτήτων που αντιστοιχούν σε κάθε μια από τις προτεινόμενες τιμές του  $\theta$ . Από αυτή είναι εμφανές πως το φίλτρο Λαϊνιώτη *MMPF*, συγκλίνει στη σωστή τάξη του μοντέλου,  $\theta = 3$ , σε πέντε βήματα. Ως κριτήριο σύγκλισης θεωρείται κάποια από τις εκ των υστέρων πιθανότητες να έχει τιμή μεγαλύτερη από 0.9.


Εκτίμηση της τάξης $\theta$						
Κριτήριο	$\theta$	1	2	3	4	5-10
<i>AIC</i>	2 (0) [0]	2 (0) [0]	6 (0) [0]	62 (88) [92]	16 (8) [8]	12 (4) [0]
<i>AICC</i>	16 (0) [0]	8 (2) [0]	14 (0) [0]	62 (96) [96]	0 (2) [4]	0 (0) [0]
<i>H &amp; Q</i>	16 (0) [0]	4 (2) [0]	12 (0) [0]	62 (98) 99	4 (0) [1]	2 (0) [0]
<i>BIC</i>	54 (8) [0]	6 (4) [0]	8 (4) [0]	32 (84) [100]	0 (0) [0]	0 (0) [0]
<i>DC</i>	12 (2) [0]	0 (2) [0]	10 (0) [0]	66 (88) [99]	8 (6) [1]	4 (2) [0]
<i>MDC</i>	12 (0) [0]	2 (2) [0]	12 (0) [0]	63 (92) [100]	7 (6) [0]	4 (0) [0]
<i>MMPF</i>	0 (0) [0]	0 (0) [0]	0 (0) [0]	100 (100) [100]	0 (0) [0]	0 (0) [0]

Πίνακας 1-5. Παράδειγμα 3<sup>0</sup>: Συχνότητα της εκτιμώμενης τάξης  $\theta$  σε 100 *MCRs* με αρχικά δεδομένα 50, 100 (σε παρένθεση) και 200 [σε αγκύλη].

Πραγματικοί Τελεστές			Εκτιμώμενοι Τελεστές			$\sqrt{\text{Μέσο Λάθος}}$		
-0.1700	-0.2000	0	-0.1730	-0.2012	0.0016	0.1101	0.1023	0.0374
-0.1900	0.2200	0.1500	-0.1730	0.2335	0.1530	0.1085	0.1096	0.0396
0.1400	0.1200	0.4000	0.1419	0.1176	0.3965	0.1078	0.0532	0.0584
-0.1000	-0.2500	-0.3700	-0.0871	-0.2452	-0.3639	0.1091	0.0553	0.0568

Πίνακας 1-6. Παράδειγμα 3<sup>0</sup>: Πραγματικοί και Εκτιμώμενοι Τελεστές και η Τετραγωνική ρίζα του αντίστοιχου Μέσου Τετραγωνικού Λάθους (*Root Mean Square Error*).

Εικ. 1-4. Παράδειγμα 3°. Ακολουθία των εκ των υστέρων πιθανοτήτων φίλτρου Λαϊνιώτη (MMPF)



**Παράδειγμα 4°:** Μοντέλο MV AR 2<sup>ης</sup> τάξης όπου  $m = 3$  με στοιχεία:

$$y_k = \sum_{i=1}^2 A_i y_{k-i} + v_k, \quad A_1 = \begin{bmatrix} 0.2520 & 0.3497 & -0.0250 \\ 0 & -0.8298 & 0.3069 \\ 0.0120 & 1.1847 & -0.9058 \end{bmatrix}, \quad A_2 = \begin{bmatrix} 1.2396 & 1.2332 & 0.7174 \\ 0.0470 & 2.3964 & 1.8011 \\ 0.2926 & 0.9093 & 2.7575 \end{bmatrix} \quad (1-28)$$

$$\text{μήτρα διασποράς } \mathbf{R} = \begin{bmatrix} 0.4 & 0 & 0 \\ 0 & 0.01 & 0 \\ 0 & 0 & 0.16 \end{bmatrix} \text{ και } M=10.$$

Το μοντέλο αυτό παρόλο που είναι 2<sup>ης</sup> τάξης ξεχωρίζει από αυτό του **Παράδειγματος 2** διότι οι τελεστές του μοντέλου είναι  $3 \times 3$ , συνεπώς έχει αυξημένη πολυπλοκότητα.

Η Εικόνα 1-5 δείχνει ότι φίλτρο Λαϊνιώτη MMPF, είναι ικανό να αναγνωρίσει και πάλι την τάξη του μοντέλου αρκετά γρήγορα, μέσα στα πρώτα είκοσι βήματα.

Ως κριτήριο σύγκλισης θεωρείται κάποια από τις εκ των υστέρων πιθανότητες να έχει τιμή μεγαλύτερη από 0.9.

Ο Πίνακας 1-7 παρουσιάζει τα εκτιμώμενα στοιχεία των τελεστών  $\{A_i\}$  του μοντέλου καθώς και την τετραγωνική ρίζα του αντίστοιχου Μέσου Τετραγωνικού Λάθους (*root mean square error – RMS Error*).

Πραγματικοί Τελεστές			Εκτιμώμενοι Τελεστές			$\sqrt{\text{Μέσο Λάθος}}$		
0.2520	-0.0250	1.2332	0.2563	-0.0289	1.0428	0.1008	0.1309	0.2103
0	0.3069	2.3964	0.0003	0.3080	2.2246	0.0254	0.0371	0.0278
0.0120	-0.9058	0.9093	0.0131	-1.0041	1.1172	0.0512	0.1020	0.1079
0.3497	1.2396	0.7174	0.3519	1.2174	0.7868	0.0563	0.0262	0.1694
-0.8298	0.0470	1.8011	-0.8969	0.0516	1.9235	0.1071	0.0126	0.1224
1.1847	0.2926	2.7575	1.2461	0.3520	2.5159	0.1814	0.0594	0.2416

Πίνακας 1-7. Παράδειγμα 4<sup>ο</sup>: Πραγματικοί και Εκτιμώμενοι Τελεστές και η Τετραγωνική ρίζα του αντίστοιχου Μέσου Τετραγωνικού Λάθους (*Root Mean Square Error*).


**Παράδειγμα 5<sup>ο</sup>:** Το παράδειγμα αυτό έχει σκοπό να δείξει ότι το φίλτρο Λαϊνώτη, *MMPF*, είναι ικανό να εντοπίζει τις όποιες αλλαγές στην τάξη του μοντέλου σε πραγματικό χρόνο (*real time*). Σε κάθε βήμα ο αλγόριθμος επιλέγει ως λύση στο πρόβλημα εκείνο το μοντέλο που αντιστοιχεί στην υψηλότερη εκ των υστέρων πιθανότητα. Αυτή η πιθανότητα τείνει ασυμπτωτικά στο μηδέν ενώ οι εναπομείνουσες τείνουν στο μηδέν. Ο αλγόριθμος μπορεί να θεωρηθεί προσαρμοζόμενος (*adaptive*) με την έννοια ότι μπορεί να εντοπίσει τις αλλαγές της τάξης του μοντέλου σε πραγματικό χρόνο.

Ο Πίνακας 1-8 παρουσιάζει το σύνολο αρχικών δεδομένων

Βήματα	Τάξη $\theta$	Βήματα	Τάξη $\theta$
1 – 50	2	171 – 200	2
51 - 90	3	201 – 240	3
91 – 170	1		

Πίνακας 1-8. Μεταβολή της τάξης  $\theta$  του μοντέλου σε σχέση με το χρόνο

Εικόνα 1-5. Παράδειγμα 4°. Ακολουθία των εκ των υστέρων πιθανοτήτων φίλτρου Λαϊνιώτη (*MMPF*)



Τα MV AR μοντέλα που χρησιμοποιήθηκαν για το σκοπό αυτής της εξομοίωσης είναι τα ακόλουθα:

$$1) \mathbf{y}_k = \sum_{i=1}^1 \mathbf{A}_i \mathbf{y}_{k-i} + \mathbf{v}_k, \quad \mathbf{A}_1 = \begin{bmatrix} -0.99101 & 8.80512 \cdot 10^{-3} \\ -0.80610 & -0.77089 \end{bmatrix}.$$

$$2) \mathbf{y}_k = \sum_{i=1}^2 \mathbf{A}_i \mathbf{y}_{k-i} + \mathbf{v}_k, \mathbf{A}_1 = \begin{bmatrix} -0.67285 & 0.08017 \\ -4.08017 & -1.99446 \end{bmatrix}, \mathbf{A}_2 = \begin{bmatrix} -0.19968 & -0.20746 \\ 3.48119 & 1.58868 \end{bmatrix}$$

$$3) \mathbf{y}_k = \sum_{i=1}^3 \mathbf{A}_i \mathbf{y}_{k-i} + \mathbf{v}_k, \mathbf{A}_1 = \begin{bmatrix} 0.0819 & 0.0615 \\ 0.0391 & 0.2874 \end{bmatrix}, \mathbf{A}_2 = \begin{bmatrix} 0.1851 & 0.3291 \\ 0.0870 & 0.0498 \end{bmatrix},$$

$$\mathbf{A}_3 = \begin{bmatrix} 0.3220 & 0.5795 \\ 0.0449 & 0.0471 \end{bmatrix}$$

Η μήτρα διασποράς του θορύβου  $\mathbf{R}$  είναι  $\begin{bmatrix} 0.02 & 0.35 \\ 0.35 & 7.6 \end{bmatrix}$  και  $M = 10$ .

Όπως και σε όλα τα προηγούμενα παραδείγματα έτσι και εδώ πραγματοποιήθηκαν 100 *MCRs*. Όπως προκύπτει από την Εικόνα 1-6 το φίλτρο Λαϊνιώτη, *MMPF*, αναγνωρίζει με επιτυχία τη σωστή τάξη του μοντέλου (η αντίστοιχη εκ των υστέρων πιθανότητα έχει τιμή μεγαλύτερη από 0.9). Κάθε φορά που συμβαίνει αλλαγή στην τάξη  $\theta$  του μοντέλου, το φίλτρο Λαϊνιώτη *MMPF* χρειάζεται  $M$  βήματα (στην εξεταζόμενη περίπτωση  $M = 10$ ) για την αρχικοποίηση των χρησιμοποιούμενων μεταβλητών. Αυτός είναι και ο λόγος που υπάρχει μια καθυστέρηση 10 βημάτων πριν το φίλτρο αρχίσει να συγκλίνει στο σωστό μοντέλο αυξάνοντας την αντίστοιχη εκ των υστέρων πιθανότητα. Η αρχικοποίηση αυτή γίνεται αυτόματα χωρίς να χρειάζεται η παρέμβαση του χρήστη [57].

## 1.5. Συμπεράσματα

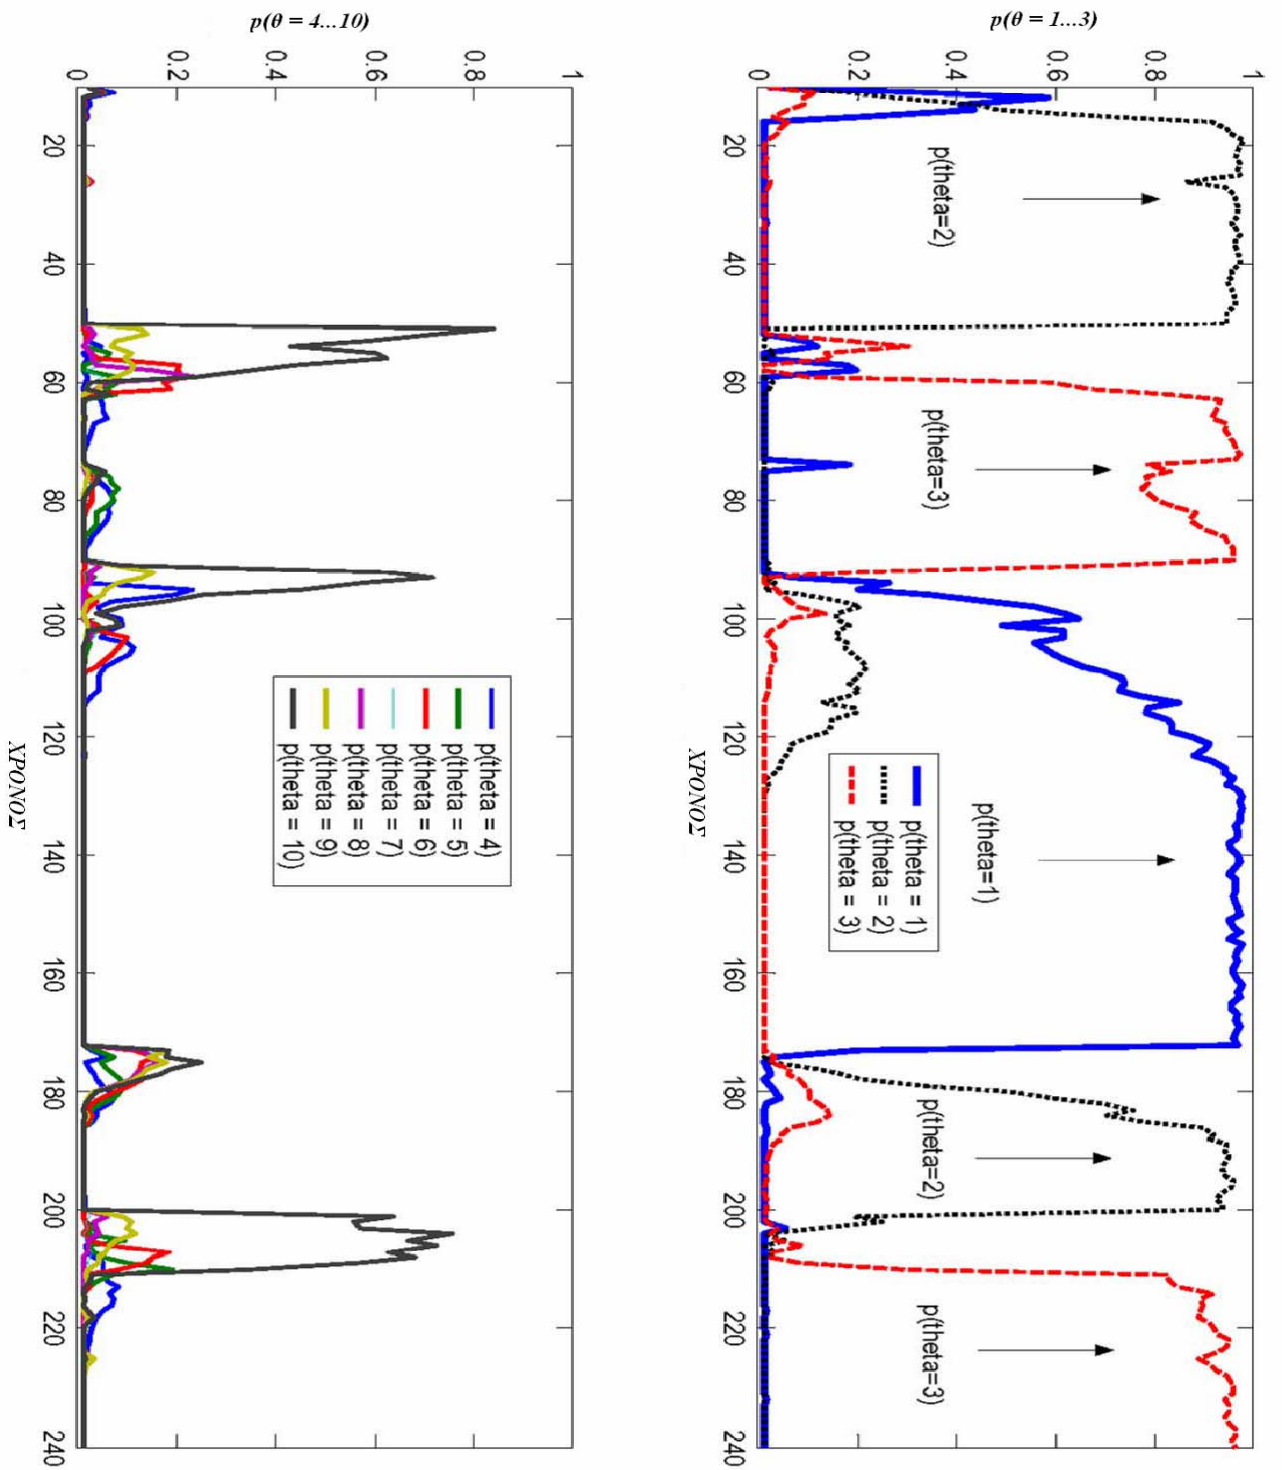
Μια καινούργια μέθοδος για ταυτόχρονη επιλογή της τάξης και εκτίμηση των τελεστών ενός *MV AR* αναπτύχθηκε και παρουσιάστηκε, ως επέκταση της μεθόδου για το βαθμωτό *AR* μοντέλο. Η προτεινόμενη μέθοδος επιλέγει με επιτυχία τη σωστή τάξη του μοντέλου σε πολύ μικρό χρόνο και αναγνωρίζει με μεγάλη ακρίβεια τους τελεστές των *MV AR* μοντέλων.

Η σύγκριση της προτεινόμενης μεθόδου με άλλα καταξιωμένα κριτήρια επιλογής της τάξης *MV AR* μοντέλων, ονομαστικά *AIC*, *AICC*, *BIC*, *H & Q*, *DC*, *MDC*, αποδεικνύει ότι μπορεί να δώσει λύση και στα δυο προβλήματα χρησιμο-

ποιώντας πάντα το μικρότερο αρχικό σύνολο δεδομένων, ενώ τα υπόλοιπα κριτήρια χρειάζονται ολοένα και μεγαλύτερο αριθμό δεδομένων καθώς η τάξη του μοντέλου αυξάνει.

Η προτεινόμενη μέθοδος αποδίδει εξίσου καλά ακόμα και όταν αυξάνει η πολυπλοκότητα του MV AR μοντέλου, (4<sup>ο</sup> Παράδειγμα ). Συμπληρωματικά η μέθοδος αποδείχθηκε ότι μπορεί να εντοπίσει τυχόν αλλαγές της τάξης του μοντέλου  $\theta$  σε πραγματικό χρόνο.

Εικ. 1-6. Παράδειγμα 5°. Ακολουθία των εκ των υστέρων πιθανοτήτων φίλτρου Λαϊνιώτη (MMPF)





## Κεφάλαιο 2

Προσαρμοζόμενη Ανίχνευση Δικτυακών  
Διαταραχών με τη χρήση Δεδομένων  
Εκμετάλλευσης Εύρους Ζώνης

## 2.1. Εισαγωγή

Είναι πλέον καθημερινή πρακτική η ανακάλυψη αδυναμιών και σφαλμάτων στην ασφάλεια των δικτύων των υπολογιστών. Δεδομένης της υπάρχουσας διασύνδεσης και πρόσβασης των υπολογιστικών συστημάτων στη σημερινή κοινωνία η εισβολή στα δίκτυα υπολογιστών και το ρήγμα στα συστήματα ασφαλείας τους αποτελούν σήμερα μια από τις πρωτεύουσες απειλές τόσο σε επίπεδο επιχειρηματικό όσο και σε επίπεδο εθνικής ασφάλειας.

Υπάρχουν δυο προσεγγίσεις στο πεδίο της *ανίχνευσης δικτυακών εισβολών (Intrusion Detection)*. Η πρώτη είναι η *ανίχνευση ανωμαλιών (anomaly detection)*, η οποία βρίσκεται στο επίκεντρο εντατικής έρευνας τα τελευταία 20 χρόνια [58], και η δεύτερη ονομάζεται *αναγνώριση κακής χρήσης – συμπεριφοράς (misuse detection)*.

Η μέθοδος της *αναγνώρισης κακής χρήσης – συμπεριφοράς* καταγράφει και μοντελοποιεί πιθανά δεδομένα εισβολής και έπειτα σημαίνει «συναγερμό» όταν η συμπεριφορά του δικτύου ταιριάζει με ένα από αυτά τα μοντέλα.

Στη αντίπερα όχθη η *ανίχνευση ανωμαλιών* καταγράφει και αναλύει ένα σύνολο δεδομένων του υπό τον έλεγχο της υπολογιστικού δικτύου και είναι σε θέση να αναγνωρίσει οποιαδήποτε δραστηριότητα που διαφέρει από τη συνηθισμένη – κανονική – συμπεριφορά του δικτύου. Είναι προφανές πως οποιαδήποτε τέτοια αποκλίνουσα δραστηριότητα χαρακτηρίζεται ως πιθανή ένδειξη εισβολής (*intrusion*) ή επίθεσης (*attack*) και έτσι αποκαλύπτονται οι αδυναμίες της ασφάλειας του εν λόγω δικτύου. Πρώτα όμως από όλα, αυτό που γίνεται είναι η δημιουργία ενός μοντέλου το οποίο περιγράφει την κανονική συμπεριφορά του δικτύου. Περιοδικός έλεγχος λογαριασμών (*audit logs*), κίνηση δικτύου (*network traffic*), εντολές χρηστών (*user commands*) και κλήσεις που πραγματοποιεί το ίδιο το σύστημα (*system calls*) είναι συνήθεις επιλογές για τη δημιουργία ενός μοντέλου περιγραφής της κανονικής συμπεριφοράς του δικτύου.

Συγκριτικά η μέθοδος της αναγνώρισης κακής χρήσης – συμπεριφοράς είναι αποτελεσματική στο να αναγνωρίζει παλαιότερους και ήδη γνωστούς τύπους δικτυακών εισβολών, ενώ η *ανίχνευση ανωμαλιών* έχει μεγάλη δυναμική στο να εντοπίζει τις όποιες προσπάθειες εισβολής που αποβλέπουν στην κατάρρευση ενός δικτύου χρησιμοποιώντας πιθανές αδυναμίες του που δεν έχουν ακόμα εντοπιστεί. Η μέθοδος μπορεί επίσης να εντοπίσει την κακοδιαχείριση προνομίων (*privilege abuse*), που γίνεται από νόμιμους χρήστες του συστήματος (*insider threat*).

Ο σκοπός της *ανίχνευσης ανωμαλιών* είναι να εντοπίζει μη κανονικές δραστηριότητες, όπως σπάνια ή ασυνήθιστα συμβάντα, με τον έλεγχο των δικτυακών δεδομένων σε τακτά χρονικά διαστήματα. Με την πάροδο των ετών πολλές μέθοδοι *ανίχνευσης ανωμαλιών* έχουν προταθεί τόσο στατιστικές όσο και μηχανικής μάθησης (*machine learning*). Ενδεικτικά αναφέρονται ορισμένες βασικές κατηγορίες όπως μέθοδοι βασισμένες σε κανόνες (*rule-based approaches*) [59], ανοσολογικές μέθοδοι (*immunological-based approaches*) [60], νευρωνικά δίκτυα (*neural nets*) [61, 62], μέθοδοι στιγμιαίας εκμάθησης (*instance-based*) [63, 64], μέθοδοι ομαδοποίησης (*clustering methods*) [65, 66], μέθοδοι εκμάθησης πιθανοτήτων, (*probabilistic learning methods*) [67, 68], ανάλυση πολυ-διασπορών (*multi-covariance analysis*) [69] και πολλές άλλες.

Παρόλα αυτά, τα πραγματικά συστήματα εντοπισμού επιθέσεων (*Intrusion Detection Systems - IDS*), βασιζόμενα στη μέθοδο *ανίχνευσης ανωμαλιών* (*anomaly detection*) δεν έχουν ικανοποιητική απόδοση και οδηγούν αρκετές φορές σε λανθασμένους συναγερμούς (*false alarm*). Οι λόγοι που συμβαίνει αυτό αναλύονται παρακάτω.

Πρώτα από όλα υπάρχει μια θεμελιώδης ασυμμετρία στα προβλήματα εντοπισμού ανωμαλιών. Η κανονική δραστηριότητα είναι συνηθισμένη και εκτεταμένη ενώ η δραστηριότητα που υποδηλώνει εισβολή είναι σπάνια. Συχνά λοιπόν κάποιος έχει να κάνει με ένα σύνολο αρχικών δεδομένων το οποίο περιέχει ελάχιστες έως καθόλου πληροφορίες από παραδείγματα εισβολών και πληθώρα παρα-

δειγμάτων κανονικής συμπεριφοράς. Αυτή λοιπόν η ανομοιογενής κατανομή των δεδομένων δημιουργεί πολλά προβλήματα στις μεθόδους μηχανικής μάθησης (*machine learning methods*) και ειδικότερα σε μεθόδους που βασίζονται στη χαρακτηριστικότητα (*discriminative methods*), οι οποίες προσπαθούν να μάθουν τη διαφορά μεταξύ κανονικής και ασυνήθιστης συμπεριφοράς.

Πολλές από τις υπάρχουσες μεθόδους απαιτούν εκμάθηση εκτός λειτουργίας του δικτύου (*off line learning*). Αυτό συνεπάγεται συγκέντρωση των δεδομένων, χειροκίνητο διαχωρισμό τους σε δεδομένα κανονικής ή ασυνήθιστης συμπεριφοράς και τελικά χρησιμοποίησή τους ώστε να εξαχθεί το μοντέλο που περιγράφει την κανονική συμπεριφορά του δικτύου. Σε πραγματικές όμως συνθήκες ένα σύστημα εντοπισμού επιθέσεων (*IDS*), λειτουργεί ασταμάτητα και νέα δεδομένα είναι διαθέσιμα κάθε στιγμή. Αυτό λοιπόν συνεπάγεται ότι θα πρέπει περιοδικά να γίνεται συχνή ενημέρωση του μοντέλου κανονικής συμπεριφοράς με «καθαρά» δεδομένα (απαλλαγμένα από παραδείγματα εισβολών) και στη συνέχεια επανεκπαίδευση του συστήματος εντοπισμού επιθέσεων. Αυτή όμως η διεργασία είναι χρονοβόρα και απαιτεί πολύ μεγάλο οικονομικό κόστος.

Επίσης αρκετές από τις στατιστικές μεθόδους όσο και τις μεθόδους μηχανικής μάθησης βασίζονται στο γεγονός ότι το αρχικό σύνολο δεδομένων προέρχεται από μια στάσιμη κατανομή. Στην πραγματικότητα όμως οι δικτυακές δραστηριότητες όπως και οι συμπεριφορά του χρήστη μπορούν να αλλάξουν για μια πληθώρα αιτιών. Έτσι λοιπόν η κανονική συμπεριφορά του δικτύου μπορεί να μην είναι αυστηρά προβλέψιμη μακροπρόθεσμα. Αυτό το πρόβλημα αναφέρεται στη βιβλιογραφία ως *concept drift* και είναι ένα ακόμα εμπόδιο στη μέθοδο *ανίχνευσης ανωμαλιών*.

Μια κοινή πρακτική για να μπορέσει να αντιμετωπιστεί το πρόβλημα του *concept drift* καθώς και οι δυσκολίες που εμφανίζουν οι μη σταθερές κατανομές των δεδομένων (*non stationary data distributions*) είναι η παραγνώριση όλων εκείνων των στατιστικών των δεδομένων που ανήκουν στο παρελθόν και η εύνοια (*favor*) των πιο πρόσφατων δεδομένων χρησιμοποιώντας ένα συντελεστή εξασθένησης ή

γήρανσης (*decay* ή *aging factor*). Για παράδειγμα το *NIDES* [69], συγκρίνει μια βραχυπρόθεσμη συμπεριφορά ενός χρήστη (*short term user behavior*) με την αντίστοιχη που έχει μακροπρόθεσμα (*long term user behavior*). Το προφίλ του χρήστη διατηρούνται στατιστικά στοιχεία των αρχικών δεδομένων, π.χ. μέση τιμή και διασπορά λάθους (*mean & covariance*), τα οποία συνεχώς «γερνούν» μέσω του πολλαπλασιασμού τους με έναν εκθετικό συντελεστή εξασθένησης. Αυτή η μέθοδος δημιουργεί ένα κινούμενο χρονικό παράθυρο όπου οι καινούργιες συμπεριφορές που προκύπτουν συγκρίνονται μόνο με τις πιο πρόσφατες καταγεγραμμένες συμπεριφορές με τις οποίες συμπίπτουν στο χρονικό παράθυρο αυτό. Ομοίως η μέθοδος *SmartSifter* [70], προτείνει τη χρησιμοποίηση «εκπτώτικών» αλγορίθμων (*discount algorithms*) με στόχο τη σταδιακή εξασθένηση της επίδρασης των παλαιότερων παραδειγμάτων, ενώ οι Mahoney and Chan, [68], οδήγησαν τη μεταβολή του συντελεστή εξασθένησης στην ακραία περίπτωση όπου απορρίπτονται οποιοδήποτε γεγονός πλην του πιο πρόσφατου.

Υπάρχει ένα πρόβλημα με την προσέγγιση του χρονικού παράθυρου που αναφέρθηκε παραπάνω. Θεωρητικά δεν υπάρχει απόδειξη αλλά ούτε και αιτιολογία για το γεγονός ότι η αλλαγή στη συμπεριφορά του χρήστη εκλαμβάνεται ως σταδιακή. Μολονότι υπάρχει αυτό το θεωρητικό κενό ο συντελεστής εξασθένησης (*decay* ή *aging factor*) συνήθως επιλέγεται με τρόπο *ad hoc*.

Εκτός από την προτεινόμενη μέθοδο που θα παρουσιαστεί παρακάτω, υπάρχουν και άλλες προσεγγίσεις για την προσαρμοζόμενη αναγνώριση επίθεσης, όπως η βασισμένη στο χρόνο επαγωγική πρακτική μάθησης (*a time-based inductive learning approach*), που προτάθηκε από τους Teng et al (1990), [71]. Βάση αυτής της πρακτικής δημιουργούνται ακολουθιακοί (*sequential*) δυναμικοί κανόνες με στόχο την κατάλληλη προσαρμογή τους στις αλλαγές της συμπεριφοράς του χρήστη. Υπάρχουν και άλλες πρακτικές, όπως αυτή της αυξητικής ενημέρωσης (*incremental update*) των παραμέτρων του συστήματος, [72], καθώς και αλγόριθμοι οι οποίοι δουλεύουν με μεικτά σύνολα αρχικών δεδομένων, με την έννοια των δεδομένων που περιέχουν και πληροφορίες εισβολής, [67]. Τέλος οι

Hossain and Bridges (2001), [73], πρότειναν έναν αλγόριθμο «εξόρυξης» συσχετισμού κανόνων χρησιμοποιώντας ασαφή λογική.

Ανακεφαλαιώνοντας, ένα αποτελεσματικό σύστημα εντοπισμού ανωμαλιών θα πρέπει να είναι ικανό ώστε να προσαρμόζεται στις αλλαγές αυτές της κανονικής συμπεριφοράς ενώ ταυτόχρονα να είναι σε θέση να αναγνωρίζει τις όποιες παραβατικές συμπεριφορές. Συμπερασματικά λοιπόν, εάν το σύστημα εντοπισμού επιθέσεων δε δύναται να προσαρμόζεται δυναμικά στα νέα μοντέλα κανονικής συμπεριφοράς που προκύπτουν χρονικά, τότε συνεχώς θα υπάρχει μεγάλη αύξηση στον αριθμό των λανθασμένων συναγερμών και μείωση της αξιοπιστίας του συστήματος.

Σε αυτήν την ενότητα παρουσιάζεται η χρησιμοποίηση απλών και εύκολα προσβάσιμων συνόλων δεδομένων, όπως εκμετάλλευση εύρους ζώνης (*bandwidth utilization*), με στόχο την εξαγωγή πληροφοριών που αφορούν την κανονική συμπεριφορά ενός δικτύου και την τελική μοντελοποίησή της. Έπειτα εφαρμόζεται η μέθοδος πολυμοντελικού διαμελισμού με στόχο την αναγνώριση ενός μοντέλου που θα περιγράψει την κίνηση του δικτύου και θα είναι σε θέση να εντοπίζει πιθανές ανωμαλίες.

Για την υλοποίηση του μοντέλου μπορούν να χρησιμοποιηθούν είτε *ARMA* είτε δυναμικά μοντέλα χώρου κατάστασης (*state space models*). Επίσης μοντελοποιούνται μια σειρά από παρελθούσες ανωμαλίες βάση των καταγεγραμμένων δεδομένων. Ο προσαρμοζόμενος μηχανισμός της προτεινόμενης μεθόδου εφαρμόζεται και σε όλα τα διαθέσιμα μοντέλα που προκύπτουν από τη συλλογή νέων δικτυακών δεδομένων. Αν το μοντέλο που προκύπτει δε συμπίπτει με εκείνο της κανονικής συμπεριφοράς του δικτύου, ο αλγόριθμος υποδεικνύει την ανωμαλία αυτή. Επίσης όταν το μοντέλο συμπίπτει με κάποιο από αυτά που αντιστοιχούν σε γνωστό τύπο παρελθούσης δικτυακής ανωμαλίας ο αλγόριθμος το αναγνωρίζει άμεσα.

Η προτεινόμενη μέθοδος έχει δυο σημαντικά πλεονεκτήματα: Πρώτον βασίζεται στα φίλτρα Λαϊνιώτη - *κεφ. 1 §2.2*, [33-35], τα οποία είναι γνωστά για τη

σταθερότητα τους, και είναι ευρύτατα εφαρμοσμένα και καθιερωμένα στο πεδίο της αναγνώρισης και της μοντελοποίησης. Δεύτερον χρησιμοποιεί εύκολα προσβάσιμα σύνολα δεδομένων όπως είναι η εκμετάλλευση του εύρους ζώνης ενός δικτύου (*Bandwidth use*) το οποίο καταγράφεται από σχεδόν όλους τους διαχειριστές δικτύου.

Κατά την εξομοίωση του αλγόριθμου χρησιμοποιήθηκαν πραγματικά δικτυακά δεδομένα από το Τ.Ε.Ι Αθηνών. Ο προτεινόμενος αλγόριθμος αναγνώρισε με επιτυχία όλες τις ασυνήθιστες δραστηριότητες του δικτύου. Η μέθοδος αποδίδει το ίδιο καλά και σε πραγματικό χρόνο χρησιμοποιώντας κατάλληλο διάστημα δειγματοληψίας όπως αυτό απαιτείται από τα προγράμματα καταγραφής της δικτυακής κίνησης.

## **2.2. Μοντελοποίηση της κίνησης δικτύου με μοντέλα τύπου ARMA και Δυναμικά Μοντέλα**

Η παρακολούθηση και η καταγραφή της κίνησης ενός δικτύου καθώς και η πρόβλεψή της παίζει πολύ σημαντικό ρόλο στο σχεδιασμό των δικτύων καθώς και στην αναβάθμισή τους. Η πρόβλεψη του «φόρτου» εργασίας ενός δικτύου είναι από τα πιο βασικά στοιχεία κατά το σχεδιασμό, την υλοποίηση, τον έλεγχο αλλά και τη διαχείριση δικτύων τύπου *LAN*, *MAN* ή *WAN*.

Θα πρέπει να αναφερθεί εδώ πως η κίνηση καθώς και η χρησιμοποίηση ενός δικτύου παρουσιάζει ημερήσια, εβδομαδιαία αλλά ακόμα και ετήσια περιοδικότητα. Μια επιτυχημένη μέθοδος μοντελοποίησης τέτοιας περιοδικής συμπεριφοράς είναι η εφαρμογή των μοντέλων *SARIMA*.

Έχει αποδειχθεί [74] ότι με τη χρησιμοποίηση μοντέλων *SARIMA* η μοντελοποίηση της εβδομαδιαίας κίνησης του δικτύου είναι επιτυχής. Σε αυτό το κεφάλαιο θα χρησιμοποιηθεί η ίδια μέθοδος προκειμένου να μοντελοποιηθεί η ημερήσια συμπεριφορά του δικτύου η οποία διακρίνεται σε δυο κατηγορίες

(α) στην κίνηση κατά τη διάρκεια εργάσιμων ημερών (Δευτέρα - Παρασκευή),

(β) στην κίνηση κατά τη διάρκεια Σαββατοκύριακου και γενικώς περιόδου διακοπών.

Τα δεδομένα τα οποία χρησιμοποιήθηκαν πάρθηκαν από το βασικό *MIB* του αναδρομολογητή (*router*). Για να αποφύγουμε προβλήματα που δημιουργεί η συσκευή ή το ίδιο το σύστημα χρησιμοποιήθηκε το *Multi Router Traffic Grapher (MRTG)*, [75], ένα καταγραφικό λογισμικό εργαλείο.

Η βασική αρχή πίσω από τη χρησιμοποιούμενη μεθοδολογία είναι πως τα δεδομένα της κίνησης του δικτύου προκύπτουν ως μια χρονική σειρά όπου οι παρατηρήσεις είναι εξαρτημένες μεταξύ τους. Αυτή η εξάρτηση δεν περιορίζεται απαραίτητα σε ένα βήμα, όπως στα μοντέλα Markov, αλλά μπορεί να επεκταθεί σε πολλά βήματα στο παρελθόν της σειράς. Έτσι, γενικεύοντας, η παρούσα τιμή  $X_t$  (η κίνηση του δικτύου τη χρονική στιγμή  $t$ ) της διεργασίας  $X$  μπορεί να εκφραστεί ως μια σειρά πεπερασμένου γραμμικού αθροίσματος περασμένων τιμών της διεργασίας καθώς και των προηγούμενων τιμών μιας τυχαίας εισόδου  $u$ , [76].

$$X_t = \varphi_1 X_{t-1} + \varphi_2 X_{t-2} + \dots + \varphi_p X_{t-p} + u_t - \theta_1 u_{t-1} - \theta_2 u_{t-2} - \dots - \theta_q u_{t-q} \quad (2-1)$$

Στην εξίσωση ( 2-1 ) η τυχαία είσοδος  $u$  αντιπροσωπεύει λευκό θόρυβο μηδενικής μέσης τιμής και διασποράς  $\sigma_u$ .

Η εξίσωση (2-1) μπορεί να γραφτεί όπως η ( 2-2 ) ορίζοντας έναν ακολουθιακό τελεστή (*AR operator*) τάξης  $p$ , όπως στην εξίσωση ( 2-4 ) και ένα τελεστή *MA* (*Moving Average*) τάξης  $q$ , όπως στην εξίσωση ( 2-3 ).

$$\varphi(B) X_t = \theta(B) u_t \quad (2-2)$$

$$\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q \quad (2-3)$$

$$\varphi(B) = 1 - \varphi_1 B - \varphi_2 B^2 - \dots - \varphi_p B^p \quad (2-4)$$

όπου

$$B_s X_t = X_{t-s} \quad (B \text{ είναι ο αναδρομικός τελεστής}) \quad (2-5)$$

ενώ ορίζουμε και τους ακόλουθους τελεστές



$$\nabla \text{ ως } \nabla X_t = X_t - X_{t-1} \quad (2-6)$$

$$\nabla = 1 - B \quad (2-7)$$

$$\nabla^d = (1 - B)^d \quad (2-8)$$

$$\nabla_s^D = (1 - B^s)^D \quad (2-9)$$

Η εξίσωση ( 2-2 ) μπορεί λοιπόν να ξαναγραφτεί χρησιμοποιώντας τους παραπάνω τελεστές {(2-6) – (2-9)} ως εξής:

$$\phi(B) \nabla^d X_t = \theta(B) u_t \quad (2-10)$$

Εμφανώς μπορεί να περιγράψει στάσιμες ( $d = 0$ ) ή μη στάσιμες ( $d \neq 0$ ) διεργασίες, καθαρά ακολουθιακές (*purely autoregressive*,  $q = 0$ ), ή καθαρά *Moving Average* ( $q \neq 0$ ). Ονομάζεται διεργασία *ARIMA AutoRegressive Integrated Moving Average Process*, τάξης ( $p, d, q$ ). Χρησιμοποιεί  $p + q + 1$  άγνωστες παραμέτρους,  $\phi_1, \dots, \phi_p; \theta_1, \dots, \theta_q; \sigma_u$ , οι οποίες θα πρέπει να εκτιμηθούν από τα δεδομένα. *ARIMA(p,d,q)* διεργασία, είναι λοιπόν μια διεργασία η οποία ‘*διαφοριζόμενη*’  $d$  φορές, παράγει μια *ARMA(p,q)* διεργασία.

Το μοντέλο της εξίσωσης ( 2-10 ) δε δύναται να περιγράψει χρονική σειρά η οποία εμπεριέχει περιοδικά στοιχεία όπως για παράδειγμα η κίνηση ενός δικτύου υπολογιστών, η ζήτηση του ηλεκτρικού φορτίου κ.λ.π. Αν η εποχικότητα της σειράς επαναλαμβάνεται με περίοδο  $s$  τότε η σειρά  $X_t$  ονομάζεται *εποχική χρονική σειρά με περίοδο s*. Το επιδιωκόμενο αποτέλεσμα είναι να απομακρυνθεί η εποχικότητα και να παραχθεί μια τροποποιημένη μη εποχική χρονική σειρά την οποία θα μπορεί να την περιγράψει επιτυχώς ένα μοντέλο ARMA.

Έστω ότι συμβολίζουμε την μη-εποχική σειρά ως  $\varepsilon_t$ . Ξεκινώντας από ένα μοντέλο *ARIMA* όπως αυτό περιγράφεται από την εξίσωση ( 2-10 ) και σύμφωνα με τη θεωρία των Box, Jenkins και Reinsel [76], δύναται να εξαχθεί το ακόλουθο μοντέλο *SARIMA* το οποίο αντιπροσωπεύει το γενικό μοντέλο που χρησιμοποιείται σε αυτό το κεφάλαιο.

$$\Phi_P(B^s) \nabla_s^D X_t = \Theta_Q(B^s) \varepsilon_t \quad (2-11)$$

όπου

$$\Theta_Q(B^s) = 1 - \theta_{1s}B^s - \theta_{2s}B^{2s} - \dots - \theta_{Qs}B^{Qs} \quad (2-12)$$

$$\Phi_P ( B^s ) = 1 - \varphi_{1s}B^s - \varphi_{2s}B^{2s} - \dots - \varphi_{ps}B^{ps} \quad (2-13)$$

Η μη εποχική σειρά ως  $\varepsilon_t$  προσεγγίζεται από ένα μοντέλο ARIMA όπως στην εξίσωση (2-10).

$$\varphi ( B ) \nabla^d \varepsilon_t = \theta ( B ) u_t \quad (2-14)$$

η σειρά  $\varepsilon_t$  περιγράφεται από ένα μοντέλο ARIMA (p, d, q). Αντικαθιστώντας τον όρο  $\varepsilon_t$  στην εξίσωση (2-11) προκύπτει το ακόλουθο μοντέλο

$$\varphi ( B ) \Phi_P ( B^s ) \nabla^d \nabla_s^D X_t = \theta ( B ) \Theta_Q ( B^s ) u_t \quad (2-15)$$

το οποίο περιγράφει μια διεργασία SARIMA (p, d, q) × (P, D, Q)<sub>s</sub>. Τα βήματα υλοποίησης του παραπάνω μοντέλου είναι τα ακόλουθα:

1. Ταυτοποίηση μοντέλου, όπου ορίζονται οι τιμές για τα  $p, d, q$ .
2. Εκτίμηση των παραμέτρων  $\{\varphi\}$  και  $\{\theta\}$ .
3. Διαγνωστικός έλεγχος της απόδοσης του μοντέλου.

Έπειτα από αρκετές δοκιμές καταλήξαμε σε ένα μοντέλο SARIMA το οποίο ικανοποιεί και τις δυο κατηγορίες συμπεριφοράς του δικτύου, (  $\alpha$  ) και (  $\beta$  ) όπως αυτές αναφέρθηκαν νωρίτερα. Το μοντέλο αυτό είναι της μορφής ARIMA (1,1,1)x(0,1,1)<sub>48</sub>, (όπου (1,1,1)x(0,1,1) = (p,d,q)x(P,D,Q)), και λειτουργεί επιτυχώς υπό την προϋπόθεση πως τα παρελθόντα δεδομένα ανήκουν στην ίδια κατηγορία με αυτά που θα προβλεφθούν, όπως δείχνουν και οι Εικόνες 2-1 και 2-2. Το μοντέλο ARIMA (1,1,1)x(0,1,1)<sub>48</sub>, που χρησιμοποιήθηκε μπορεί επίσης να γραφτεί και ως:

$$\varphi(B) \nabla^1 \nabla_{48}^1 X_k = \theta(B) \Theta(B^{48}) u_k \quad (2-16)$$

με τις ακόλουθες παραμέτρους:

$$\varphi(B) = 1 - \varphi_1 B, \quad \theta(B) = 1 - \theta_1 B, \quad \Theta(B^{48}) = 1 - \Theta_1 B^{48} \quad (2-17)$$

όπου  $B^s X_k = X_{k-s}$  and  $\nabla_s^D = (1 - B^s)^D$ .

Συνεπώς η αναλυτική μορφή της εξίσωσης (2-12) είναι:

$$(1 - \varphi_1 B)(1 - B)(1 - B^{48}) X_k = (1 - \theta_1 B)(1 - \Theta_1 B^{48}) u_k \Rightarrow$$


$$X_k - (1 + \varphi_1)X_{k-1} + \varphi_1 X_{k-2} - X_{k-48} + (1 + \varphi_1)X_{k-49} - \varphi_1 X_{k-50} = u_k - \theta_1 u_{k-1} - \Theta_1 u_{k-48} + \theta_1 \Theta_1 u_{k-49} \quad (2-18)$$

Επίσης

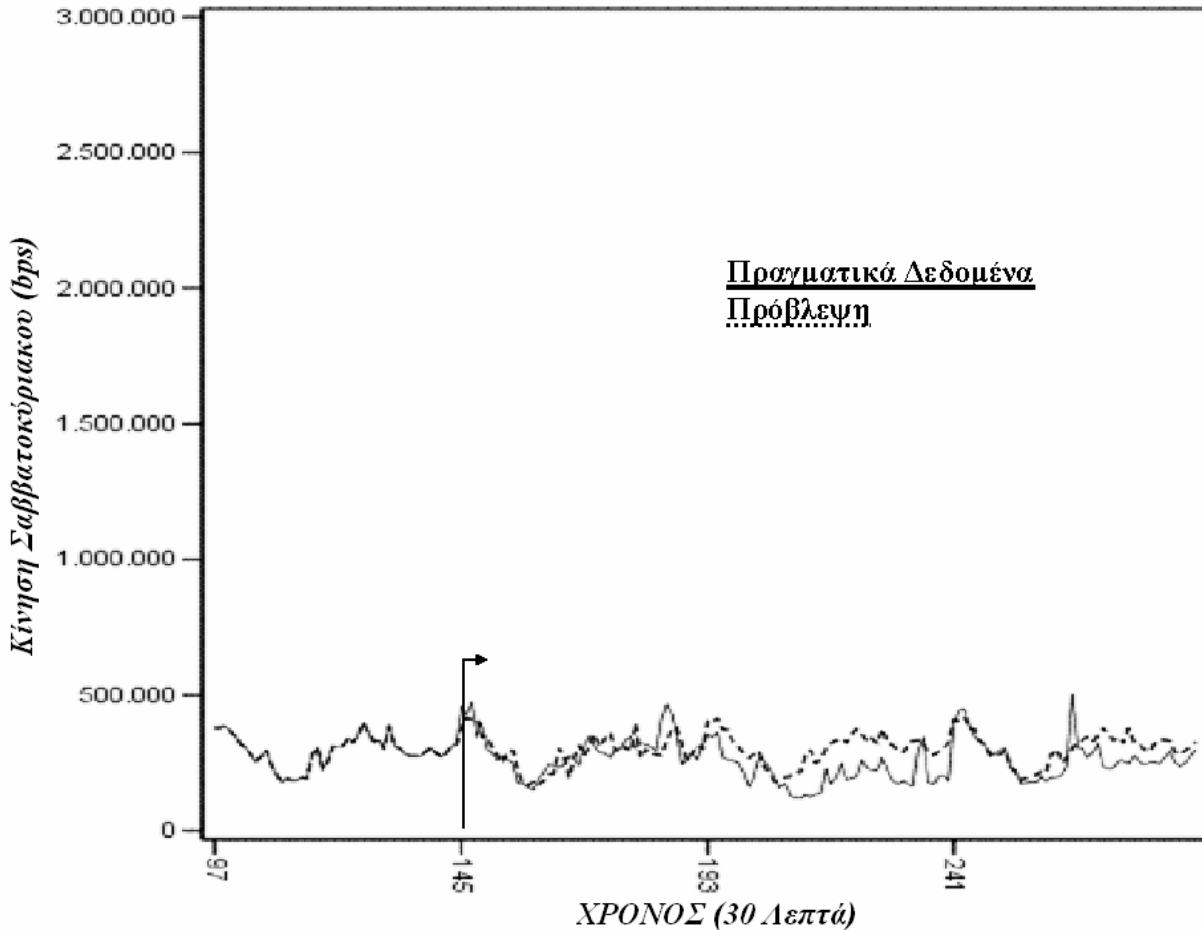
$$\varphi_1 = 0.413027, \theta_1 = 0.942437, \Theta_1 = 0.959323$$

Σε αυτό το σημείο θα πρέπει να σημειωθεί πως για την εύρεση των συντελεστών του μοντέλου *SARIMA*,  $(p,d,q) \times (P,D,Q)$ ,  $s$ ,  $\varphi_1$ ,  $\theta_1$ ,  $\Theta_1$ , χρησιμοποιήθηκε το λογισμικό πακέτο *SPSS*<sup>®</sup>.

**Εικ. 2-1.** Ημερήσια εκτίμηση της κίνησης του δικτύου σε εργάσιμη ημέρα, χρησιμοποιώντας το μοντέλο *ARIMA*  $(1,1,1) \times (0,1,1)_{48}$ . Η εκτίμηση ξεκινά στο βήμα 145 (άρα με μια υστέρηση - *lag* - 48 βημάτων. ). Τα προηγούμενα βήματα (97 - 144) αντικαταστάθηκαν από το μέσο όρο όλων των προηγούμενων εργάσιμων ημερών.



**Εικ. 2-2.** Ημερήσια εκτίμηση της κίνησης του δικτύου σε ημέρα Σαββατοκύριακου ή άλλης αργίας, χρησιμοποιώντας το μοντέλο ARIMA (1,1,1)×(0,1,1)<sub>48</sub>. Η εκτίμηση ξεκινά στο βήμα 145 (άρα με μια υστέρηση - lag - 48 βημάτων. ). Τα προηγούμενα βήματα (97 - 144) αντικαταστάθηκαν από το μέσο όρο όλων των προηγούμενων Σαββατοκύριακων ή αργιών.



Για να είμαστε συνεπείς με τη σημειολογία του φίλτρου Λαϊνιώτη (*MMPF*) και του φίλτρου Kalman η εξίσωση ( 2-18 ) μπορεί να γραφεί χρησιμοποιώντας το ακόλουθο δυναμικό μοντέλο,[50]:

$$x_{k+1} = \begin{bmatrix} -a_1 & I & \cdots & 0 & 0 \\ -a_2 & \vdots & \ddots & \vdots & \vdots \\ \vdots & \vdots & \cdots & I & 0 \\ -a_{n-1} & 0 & \cdots & 0 & I \\ -a_n & 0 & \cdots & 0 & 0 \end{bmatrix} x_k + \begin{bmatrix} b_1 - a_1 b_0 \\ b_2 - a_2 b_0 \\ \vdots \\ \vdots \\ \vdots \end{bmatrix} u_k, \quad z_k = [I \ 0 \ \cdots \ 0 \ 0] x_k + b_0 u_k \quad (2-19)$$

$$z_k + a_1 z_{k-1} + \dots + a_n z_{k-n} = b_0 u_k + \dots + b_m u_{k-m}$$

Εκτός από τη συνηθισμένη δικτυακή κίνηση υπάρχουν και μια σειρά από άλλες καταστάσεις όπως βλάβες στις γραμμές (*line failures*) ή κακή χρήση (*network misuse*). Αυτά τα συμβάντα δεν είναι περιοδικά αλλά εμφανίζονται σε τυχαίες χρονικές στιγμές, συνεπώς το περιοδικό μοντέλο δεν εξυπηρετεί ιδιαίτερα. Εδώ μοντελοποιούνται δυο τέτοια συμβάντα, μια ξαφνική αύξηση της δικτυακής κίνησης (*peak - misuse*) και μια βλάβη γραμμής (*link failure*), χρησιμοποιώντας δυναμικά μοντέλα (*state space models*) ως εξής:

$$z_k = x_k + v_k, \quad \text{and,} \quad a) x_{k+1} = 10 \cdot x_k, \quad b) x_{k+1} = x_k \quad (=0) \quad (2-20)$$

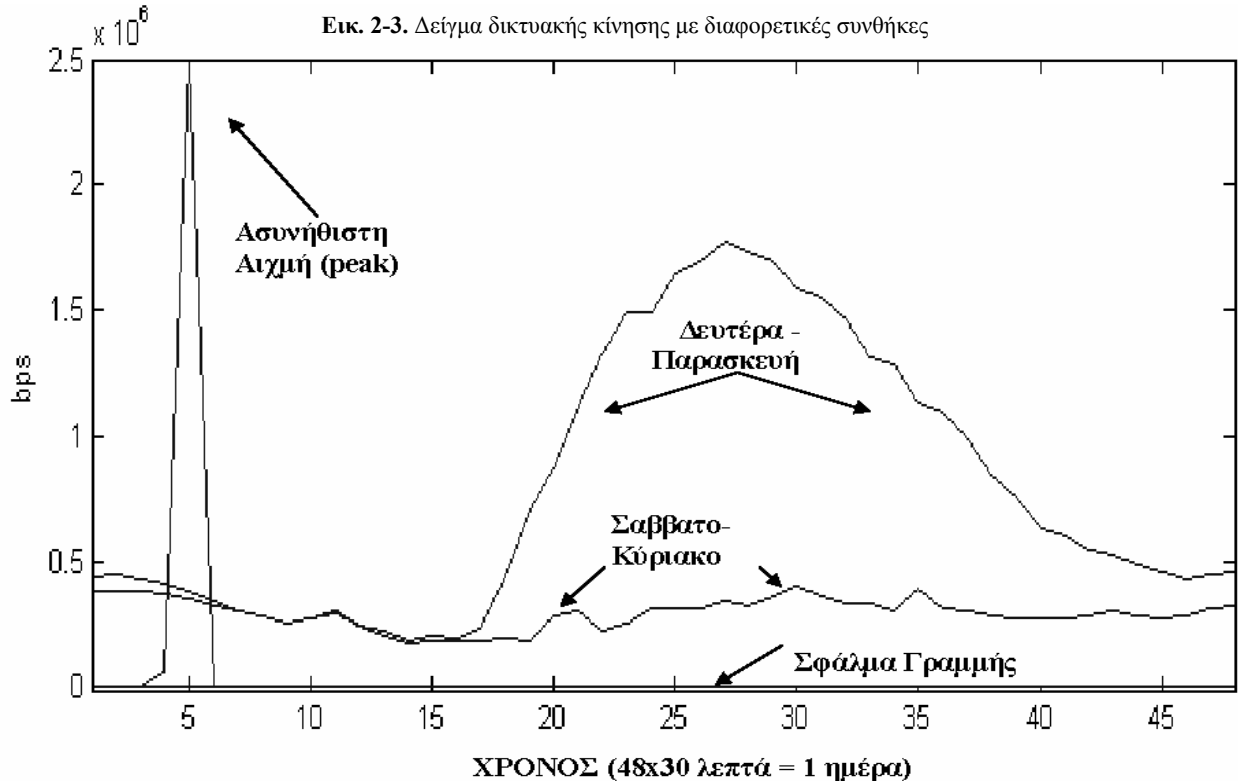
Τα τέσσερα υποψήφια μοντέλα που περιγράφηκαν παραπάνω (δικτυακή κίνηση εργάσιμων ημερών, δικτυακή κίνηση Σαββατοκύριακου και αργιών, ξαφνική αύξηση της κίνησης, και βλάβη γραμμής) θα χρησιμοποιηθούν σε συνδυασμό με το φίλτρο Λαϊνιώτη (*MMPF*) με στόχο τον εντοπισμό της δικτυακής χρήσης. Ένα δείγμα της κάθε μιας δικτυακής ακολουθίας που αναπαριστάται από τα παραπάνω μοντέλα απεικονίζεται στην Εικόνα 2-3.

### 2.3. Αποτελέσματα

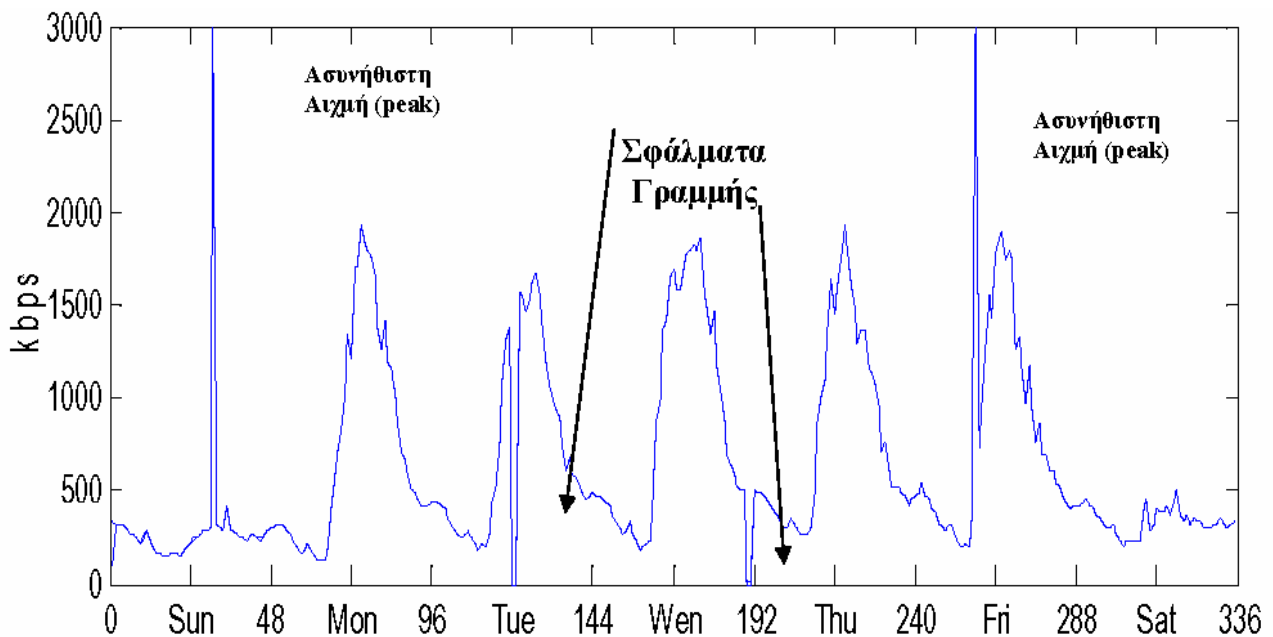
Πραγματικά δεδομένα από το Τ.Ε.Ι Αθηνών χρησιμοποιήθηκαν προκειμένου να μελετηθεί η απόδοση του αλγόριθμου Λαϊνιώτη. Το σύνολο των δεδομένων δημιουργήθηκε από πραγματικές δικτυακές καταστάσεις. Η Εικόνα 2-4 περιέχει δεδομένα από 5 εργάσιμες ημέρες και ένα Σαββατοκύριακο. Σε αυτό το σύνολο δεδομένων έχουν εισαχθεί 2 βλάβες γραμμών (*link failure*) καθώς και 2 ξαφνικές αυξήσεις στην κίνηση (*high traffic peaks*).

Το φίλτρο Λαϊνιώτη χρησιμοποιεί 4 στοιχειώδη φίλτρα Kalman, κάθε ένα από τα οποία αντιστοιχεί σε μια από τις 4 δικτυακές καταστάσεις, όπως φαίνεται στην Εικόνα 2-3. Η εκ των υστέρων πιθανότητα  $p(n / k)$  του κάθε μοντέλου χρησιμοποιείται για να ταυτοποιηθεί ο τύπος της δικτυακής κίνησης. Το μοντέλο στο ο-

ποίο αντιστοιχεί η μεγαλύτερη εκ των υστέρων πιθανότητα επιλέγεται από τον αλγόριθμο ως το σωστό.

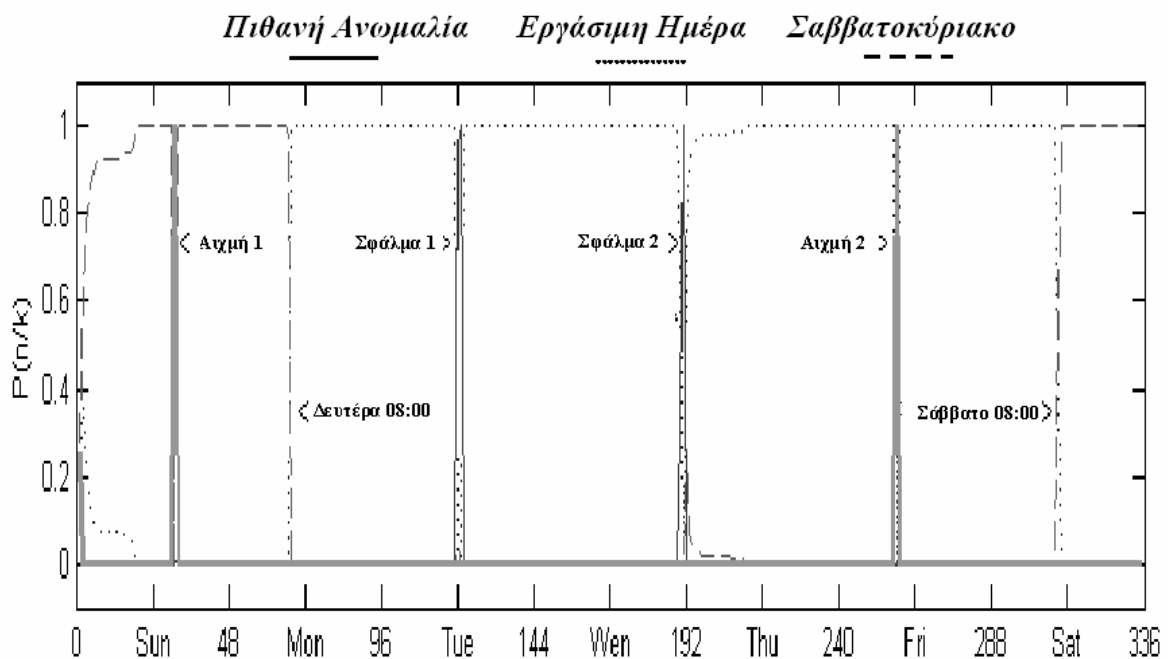


Εικ. 2-4. Σύνολο Δεδομένων για μια εβδομάδα. Εμπεριέχει ξαφνικές αυξήσεις στην κίνηση (peaks) και βλάβες στη γραμμή (line failures)



Όπως φαίνεται από την Εικόνα 2-5, η προτεινόμενη μέθοδος εντοπίζει επιτυχώς τόσο τις αλλαγές στην κίνηση του δικτύου από Σαββατοκύριακο σε εργάσιμη ημέρα όσο και το αντίστροφο. Επίσης η μέθοδος εντοπίζει εξίσου καλά την κακή χρήση (αύξηση στην κίνηση, *misuse - peaks*) καθώς και τις βλάβες στη γραμμή (*link failure*). Επιπρόσθετα ο προσαρμοζόμενος (*adaptive*) προτεινόμενος αλγόριθμος εκτελεί κάθε απαραίτητο υπολογιστικό βήμα σε κλάσματα δευτερολέπτου επιτρέποντάς μας έτσι να αυξήσουμε το ρυθμό δειγματοληψίας από τα παρεχόμενα δεδομένα. Ο προκαθορισμένος ρυθμός συγκέντρωσης δεδομένων μέσω του δρομολογητή (*router*) είναι 5 λεπτά. Η ρύθμιση του ρυθμού δειγματοληψίας είναι κρίσιμη λεπτομέρεια για τον *online* εντοπισμό των δικτυακών ανωμαλιών.

Εικ. 2-5. Το φίλτρο Λαϊνιώτη εντοπίζει με επιτυχία τις αλλαγές στη δικτυακή κίνηση.



## 2.4. Συμπεράσματα

Στο κεφάλαιο αυτό εφαρμόστηκε το αυτοπροσαρμοζόμενο φίλτρο πολυμοντελικού διαμελισμού με στόχο την ανίχνευση των ανωμαλιών αλλά και της κακής χρήσης του δικτύου χρησιμοποιώντας δεδομένα εκμετάλλευσης εύρους ζώνης.

Το φίλτρο βασίζεται σε παλαιότερα δεδομένα δικτυακής κίνησης προκειμένου να μοντελοποιήσει την περιοδική συμπεριφορά του δικτύου. Για το σκοπό αυτό χρησιμοποιήθηκαν μοντέλα ARIMA. Το αυτοπροσαρμοζόμενο φίλτρο πολυμοντελικού διαμελισμού επεξεργάστηκε επιτυχώς τα πραγματικά δεδομένα και όπως έδειξαν τα αποτελέσματα ανίχνευσε με επιτυχία τις αλλαγές, τις ασυνήθιστες διεργασίες και τα λάθη που περιέχονταν στο σύνολο των δεδομένων. Επιπλέον το φίλτρο ανταποκρίνεται πολύ γρήγορα στις αλλαγές αυτές και μπορεί να αποδώσει το ίδιο καλά σε πραγματικό χρόνο ακόμα και για διαστήματα δειγματοληψίας μικρότερα των 5 λεπτών.



## Κεφάλαιο 3

Παράλληλη αναγνώριση των τελεστών και της τάξης πολυ-μεταβλητών μοντέλων μεικτών διεργασιών - ARMA

### 3.1. Εισαγωγή

Το κεφάλαιο αυτό πραγματεύεται την εφαρμογή του αλγορίθμου πολυ-μοντελικού διαμελισμού για την ταυτόχρονη αναγνώριση της τάξης και των παραμέτρων μοντέλων μεικτών διεργασιών. Η εκτίμηση και η επιτυχής χρησιμοποίηση του κατάλληλου μοντέλου σε μια δεδομένη χρονική σειρά είναι ένα πρόβλημα το οποίο εμφανίζεται σε μια σειρά εφαρμογών όπως:

- Ανάλυση ομιλίας, (*speech analysis*), [77],
- Βιο-ιατρική, (*biomedical applications*), [78],
- Υδρολογία, [79],
- Ηλεκτρικά συστήματα ισχύος, [80],
- Προσομοίωση σεισμικών δονήσεων, [81],
- Κατασκευές, [82] κ.α

Ο σκοπός του κεφαλαίου αυτού δεν είναι η παρουσίαση ενός ακόμα κριτηρίου για την ταυτόχρονη αναγνώριση της τάξης και των παραμέτρων *MV ARMA* μοντέλων, στην ήδη αρκετά πλούσια βιβλιογραφία επάνω στο θέμα αυτό. Ο στόχος επικεντρώνεται στην επέκταση της μεθόδου που εφαρμόστηκε επιτυχώς για τα *MV AR* μοντέλα [57]. Η μέθοδος βασίζεται στην πολύ γνωστή και πλειστάκις εφαρμοσμένη θεωρία του αυτο-προσαρμοζόμενου πολυ-μοντελικού διαμελισμού (*adaptive multi-model partition theory*) ή απλούστερα φίλτρο *Λαϊνιώτη* [33-35]. Δεν περιορίζεται μόνο στην περίπτωση θορύβου *Gauss*, μπορεί να εφαρμοστεί *on-line*, δεν απαιτεί μεγάλο υπολογιστικό φόρτο και όπως θα φανεί από τις προσομοιώσεις μπορεί με μικρό αρχικό σύνολο δεδομένων να επιτύχει την ταυτόχρονη αναγνώριση της τάξης και των συντελεστών του *MV ARMA* μοντέλου.

Η περιγραφή ενός *MV ARMA* μοντέλου τάξης  $(p, q)$  [*ARMA*  $(p, q)$ ] το οποίο αντιστοιχεί σε μια στάσιμη χρονική σειρά διανυσμάτων  $\mathbf{y}$ , που έχουν επιλεχθεί σε  $k$  ( $k = 1, 2, \dots, I$ ) ισαπέχουσες χρονικές στιγμές ορίζεται ακολούθως:

$$\mathbf{y}_k = \sum_{i=1}^p \mathbf{A}_i \mathbf{y}_{k-i} + \sum_{j=1}^q \mathbf{B}_j \mathbf{v}_{k-j} + \mathbf{v}_k, \quad \mathbf{E}[\mathbf{v}_k \mathbf{v}_k^T] = \mathbf{R} \quad (3-1)$$

$\mathbf{v}_k$  είναι το διάνυσμα του τυχαίου ανεξάρτητου θορύβου, με μήτρα διασποράς  $\mathbf{R}$ , διάσταση  $m$ , μέση τιμή  $\theta$ ,  $\theta = (p, q)$  είναι η τάξη του μοντέλου, άρα και η επιθυμητή τάξη του εκτιμώμενου μοντέλου και οι  $m \times m$  πίνακες  $\mathbf{A}_1, \dots, \mathbf{A}_p, \mathbf{B}_1, \dots, \mathbf{B}_q$  αποτελούν τους συντελεστές του *MV ARMA* μοντέλου.

Όπως και στην περίπτωση του *MV AR* έτσι και εδώ το πρόβλημα μπορεί να χωριστεί σε 2 μέρη. Το πρώτο και δυσκολότερο είναι η επιτυχής αναγνώριση της τάξης  $\theta = (p, q)$  του εκτιμητή. Όταν αυτό επιτευχθεί ακολουθεί ο υπολογισμός του συνόλου των συντελεστών  $\{\mathbf{A}_i, \mathbf{B}_j\}$  του γραμμικού εκτιμητή.

Η σωστή εκτίμηση της τάξης ενός *MV ARMA* μοντέλου αποτελεί ένα σημαντικό επιστημονικό πρόβλημα και η επίλυσή του είναι κάτι που απασχολεί τους επιστήμονες αρκετά χρόνια τώρα. Όπως είναι αναμενόμενο υπάρχει πλούσια βιβλιογραφία γύρω από το αντικείμενο. Ενδεικτικά αναφέρουμε τα ακόλουθα κριτήρια

- *Akaike's Information Criterion (AIC)* [8], [83], [84]
- *Schwarz's Bayesian Information Criterion (BIC)* [19]
- *Rissanen's* [20, 21]
- *Wax's* [22]

Όπως και στην περίπτωση της αναγνώρισης της τάξης των *MV AR* μοντέλων, τα σχόλια της παραγράφου 5 – σελίδα 17- του υποκεφαλαίου 1.1 με τα χαρακτηριστικά των προαναφερθέντων κριτηρίων ισχύουν και στην περίπτωση που εξετάζεται εδώ.

Για να συμπληρωθεί η παραπάνω λίστα αναφέρονται και κάποιες *γραφικές μέθοδοι* υπολογισμού της τάξης των *MV ARMA* μοντέλων, οι οποίες βασίζονται στις συναρτήσεις συνέλιξης (*correlation function*) και μερικής συνέλιξης (*partial correlation function*) όπως τα κριτήρια *ACF* και *PACF* και παρουσιάστηκαν από τους Box, Jenkins και Reinsel, [76]. Επίσης προσφάτως στη βιβλιογραφία εμφανίστηκαν αρκετές μέθοδοι εκτίμησης παραμέτρων *MV ARMA* μοντέλων, ενδεικτικά αναφέρονται τα [85], [86], [87], [88], [89], [90],[91] Οι μέθοδοι [86], [87], και [90] στηρίζονται στο γεγονός πως ένα *MV ARMA* ( $p, q$ ) μπορεί με ασφάλεια να περιγραφεί μέσω μοντέλων *MV AR* ή *MV MA* υψηλής τάξης. Οι μέθοδοι αυτές

μπορούν να εκτιμήσουν μόνο τους συντελεστές του  $MV ARMA(p, q)$  σε αντίθεση με το φίλτρο *Λαϊνιώτη* το οποίο είναι ικανό, πέρα από τους συντελεστές, να δώσει και μια ακριβή εκτίμηση αθροιστικά της τάξης  $\theta = p + q$ .

### 3.2 Επαναδιατύπωση του προβλήματος

Η επαναδιατύπωση του προβλήματος, δεν διαφέρει πολύ από τη δουλειά που έχει ήδη γίνει για την εκτίμηση της τάξης και των παραμέτρων  $MV AR$  μοντέλων. Παρόλ' αυτά υπάρχουν κάποιες αλλαγές στις διαστάσεις των παραμέτρων.

Ας υποθέσουμε αρχικά ότι η τάξη του μοντέλου  $\theta$  είναι γνωστή. Η εξίσωση (3-1) μπορεί να περιγραφεί από τις εξισώσεις (1-3) και (1-4), με τις ακόλουθες τροποποιήσεις:

το διάνυσμα  $\mathbf{x}(k)$  έχει διάσταση  $m^2(p + q) \times 1$  και απαρτίζεται από όλους τους όρους των πινάκων  $\{ \mathbf{A}_1, \dots, \mathbf{A}_p, \mathbf{B}_1, \dots, \mathbf{B}_q \}$ ,

και το διάνυσμα  $\mathbf{H}(k)$  έχει διάσταση  $m \times m^2(p + q)$  και περιέχει το ιστορικό της ακολουθίας των μετρήσεων  $\{ \mathbf{y}(k) \}$  έως και τη χρονική στιγμή  $k - (p + q)$ .

Έστω ότι η γενική μορφή κάθε πίνακα είναι:

$$\mathbf{A}_p \text{ είναι } \begin{bmatrix} a_{11}^p & \dots & a_{1m}^p \\ \vdots & \ddots & \vdots \\ a_{m1}^p & \dots & a_{mm}^p \end{bmatrix} \text{ και}$$

$$\mathbf{B}_q \begin{bmatrix} b_{11}^q & \dots & b_{1m}^q \\ \vdots & \ddots & \vdots \\ b_{m1}^q & \dots & b_{mm}^q \end{bmatrix} \text{ τότε μπορούμε να γράψουμε τα διανύσματα } \mathbf{x}(k) \text{ και } \mathbf{H}(k)$$

ως εξής:

$$\mathbf{x}(k) \triangleq [\alpha_{11}^1 \alpha_{21}^1 \dots \alpha_{m1}^1 : \alpha_{12}^1 \alpha_{22}^1 \dots \alpha_{m2}^1 : \dots : \alpha_{1m}^1 : \dots : \alpha_{mm}^1 : \dots : \alpha_{11}^p : \dots : \alpha_{mm}^p : b_{11}^1 b_{21}^1 \dots b_{m1}^1 : b_{12}^1 b_{22}^1 \dots b_{m2}^1 : \dots : b_{1m}^1 : \dots : b_{mm}^1 ]^T \quad (3-2)$$

$$\mathbf{H}(k) \triangleq [y_1(k-1)I \dots y_m(k-1)I : \dots : y_1(k-p)I \dots y_m(k-p)I : v_1(k-1)I \dots v_m(k-1)I : \dots : v_1(k-q)I \dots v_m(k-q)I] \quad (3-3)$$

όπου  $\mathbf{I}$  είναι ταυτοτικός πίνακας διαστάσεων  $m \times m$  και  $\theta = (p, q)$  η τάξη του μοντέλου.

Στην περίπτωση που γνωρίζαμε τόσο το μοντέλο του συστήματος όσο και τις στατιστικές παραμέτρους του, το *Φίλτρο Kalman* στις διάφορες μορφές του θα ήταν ο βέλτιστος γραμμικός εκτιμητής (με την έννοια του ελάχιστου μέσου τετραγωνικού λάθους - *MMSE*).

Όπως και στην περίπτωση των *MV AR* μοντέλων έτσι και εδώ υποθέτουμε ότι στο σύστημά μας υπάρχει παραμετρική αβεβαιότητα η οποία εντοπίζεται στην άγνοια της τάξης  $\theta (p, q)$ , του μοντέλου. Επίσης θεωρούμε ότι η τιμή της παραμέτρου  $\theta$ , βρίσκεται μέσα σε γνωστό διακριτό δειγματικό χώρο  $\mathcal{T}$  έτσι ώστε  $1 \leq \theta \leq M$ ,  $\theta \in \mathcal{T}$ , όπου  $\mathcal{T}$ , υποδηλώνει το σύνολο των ακέραιων αριθμών.

Για να καταστεί δυνατή η αντιμετώπιση ενός τέτοιου προβλήματος το *αυτοπροσαρμοζόμενο φίλτρο πολυμοντελικού διαμελισμού*, (*MMPF*) ή *φίλτρο Λαϊνιώτη* είναι αυτό που εφαρμόζεται περισσότερο. Αυτή η μέθοδος παρουσιάστηκε από τον *Δ. Γ. Λαϊνιώτη* [33-35], και όπως έχει αναφερθεί στο **1<sup>ο</sup> κεφάλαιο** συγκεντρώνει όλη την παραμετρική αβεβαιότητα του μοντέλου σε ένα άγνωστο, πεπερασμένης διάστασης διάνυσμα του οποίου οι τιμές μπορούν να αναζητηθούν ανάμεσα από ένα άλλο γνωστό σύνολο πεπερασμένου πληθικού αριθμού (*finite cardinality*).

Οι παρατηρήσεις 1-11, που έγιναν στο 1<sup>ο</sup> κεφάλαιο, § 1.2, ισχύουν και εδώ με τις ακόλουθες μεταβολές:

$$\mathbf{w}(k) \triangleq [w_{11}^l \ w_{21}^l \ \dots \ w_{m1}^l : w_{12}^l \ w_{22}^l \ \dots \ w_{m2}^l : \dots \ w_{mm}^l : \dots \ w_{mm}^p : w_{11}^l \ w_{21}^l \ \dots \ w_{m1}^l : w_{12}^l \ w_{22}^l \ \dots \ w_{m2}^l : \dots \ w_{mm}^l : \dots \ w_{mm}^q]^T$$

Η αρχικοποίηση των παραμέτρων του φίλτρου Λαϊνιώτη (*MMPF*) γίνεται ως εξής:

$$\hat{\mathbf{x}}(0/0; \theta_j) = [1 \ 1 \ 1 \ \dots \ 1]^T, \text{ η διάσταση του διανύσματος είναι } m^2 j \times 1,$$

$$\mathbf{P}(0/0; \theta_j) = \begin{bmatrix} 50 & 0 & \dots & 0 \\ 0 & 50 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & 50 \end{bmatrix}, \text{ διαγώνιος πίνακας με διάσταση } m^2 j \times m^2 j \text{ και}$$

$$p(\theta_j/k) = 1/M, \text{ όπου } j = 1, 2, \dots, M.$$

Σε αυτό το σημείο θα πρέπει να αναφερθεί πως στην παρούσα μελέτη αντιμετωπίσαμε το πρόβλημα του διαχωρισμού της τάξης  $p$  του  $AR$  μοντέλου από την τάξη  $q$  του μοντέλου  $MA$ . Μια προσέγγιση θα ήταν να επεξεργαστούμε τα δεδομένα δυο φορές χάνοντας με αυτόν τον τρόπο το πλεονέκτημα του αλγόριθμου που είναι *one-pass*. Μια άλλη προσέγγιση είναι η υλοποίηση όσων υποφίλτρων χρειάζονται ώστε να καλυφθούν όλοι οι δυνατοί συνδυασμοί  $(p, q)$  της τάξης του μοντέλου  $ARMA$ . Το τελευταίο είναι αρκετά δύσκολο να εφαρμοστεί σε πραγματικά προβλήματα καθώς όσο η τάξη του μοντέλου  $ARMA$  μεγαλώνει θα πρέπει να υλοποιείται όλο και μεγαλύτερος αριθμός υποφίλτρων γεγονός που αυξάνει σημαντικά τον υπολογιστικό φόρτο. Αυτό που γίνεται εδώ είναι η εκτίμηση της τάξης του μοντέλου  $\theta$  ως το άθροισμα των  $p, q$ .

### 3.3. Παρουσίαση των συγκρινόμενων κριτηρίων

Η πλειοψηφία των κλασικών μεθόδων και κριτηρίων επιλογής της τάξης ενός  $MV ARMA$  μοντέλου βασίζονται στην ελαχιστοποίηση μιας αντικειμενικής συνάρτησης (*objective function*). Πιο συγκεκριμένα σε αυτή τη θεματική ενότητα θα συγκρίνουμε το φίλτρο *πολύ-μοντελικού διαμελισμού (MMPF)* με δυο άλλα καταξιωμένα κριτήρια επιλογής τα οποία είναι το *Akaike's Information Criterion (AIC)*, [8], [83], και το *Schwarz's Bayesian Information Criterion (BIC)*, [19].

Και τα δυο προαναφερθέντα κριτήρια βασίζονται στην ελαχιστοποίηση μιας συνάρτησης κόστους. Αναλυτικότερα:

- Το κριτήριο του *Akaike (AIC)*:  $AIC(m) = \log\left(\left|\hat{\mathbf{R}}_\theta\right|\right) + \frac{2(p+q)}{n}$  (3-4)

- Το κριτήριο του Schwarz (*BIC*):  $BIC(m) = n \log(|\hat{\mathbf{R}}_\theta|) + (p+q) \log(n)$  (3-5)

όπου  $n$  είναι το μέγεθος του δείγματος,  $p$ ,  $q$ , η τάξη του μοντέλου AR και ARMA αντίστοιχα και  $\hat{\mathbf{R}}_\theta$  είναι η εκτίμηση μέγιστης πιθανοφάνειας (*maximum likelihood estimate*) της μήτρας διασποράς  $\mathbf{R}$ .

Το επιθυμητό μοντέλο είναι αυτό που ελαχιστοποιεί τις (3-4) και (3-5). Το κριτήριο *AIC* μπορεί να ελαχιστοποιηθεί για διάφορες τιμές του πλήθους παραμέτρων  $m$  πάντα όμως με κόστος την καλή εφαρμογή του μοντέλου στα δεδομένα και την πολυπλοκότητα του μοντέλου. Το κριτήριο *AIC* προσπαθεί να αντιστοιχίσει στα δεδομένα ένα μοντέλο με όσο το δυνατό λιγότερες ελεύθερες παραμέτρους (άλλωστε χρησιμοποιεί γι' αυτό το σκοπό ένα *συντελεστή ποινής* ο οποίος αυξάνει όσο αυξάνει ο αριθμός των εκτιμώμενων παραμέτρων) εφαρμόζοντας την αρχή *Occham Razor*, [93]. Η αρχή αυτή λέει πως μεταξύ δύο ικανοποιητικών και σωστών εξηγήσεων ενός φαινομένου κάποιος πρέπει να ενστερνίζεται αυτήν που είναι λιγότερο περίπλοκη. Επίσης αναφέρει πως όσο λιγότερες είναι οι υποθέσεις (*assumptions*) από τις οποίες εξαρτάται ένα φαινόμενο τόσο το καλύτερο. Στην ίδια βάση κινείται και το κριτήριο *BIC* το οποίο όμως χρησιμοποιεί ακόμα πιο αυστηρό *συντελεστή ποινής* όσο αυξάνει ο αριθμός των εκτιμώμενων παραμέτρων, για να αποφευχθεί έτσι ο κίνδυνος της υπερεκτίμησης. Από την άλλη πλευρά έχει παρατηρηθεί πως η συμπεριφορά των δυο προαναφερθέντων κριτηρίων είναι πολύ ευαίσθητη ως προς την επιλογή του *συντελεστή ποινής*, ο οποίος αλλάζει ανάλογα με την εφαρμογή, [94] και η απόδοσή τους έχει τεθεί υπό αμφισβήτηση [95].

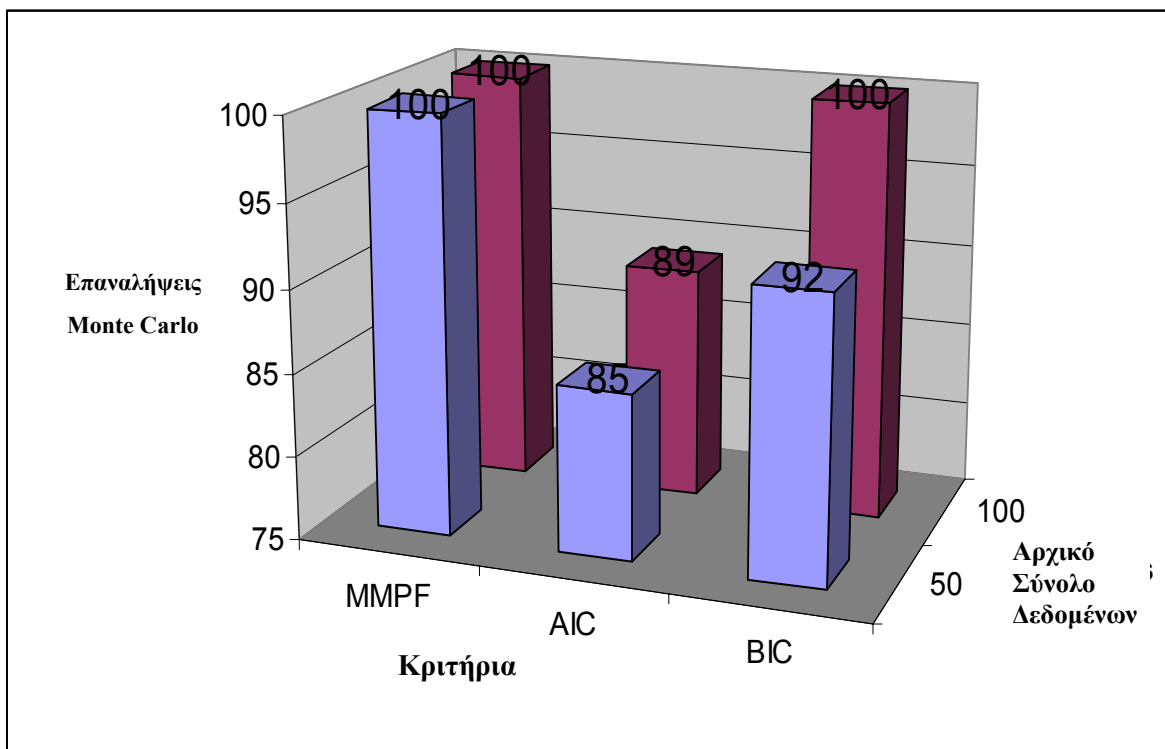
### 3.4. Παραδείγματα και αποτελέσματα

**Παράδειγμα 1<sup>ο</sup>:** Μοντέλο MV ARMA (1, 1).  $\theta = (I, I) = 2$ ,  $M = 10$ .

$$\mathbf{A} = \begin{bmatrix} -0.85 & 0.75 \\ 0.65 & -0.55 \end{bmatrix}, \mathbf{B} = \begin{bmatrix} -1.9833 & 1.889 \\ 1.7 & 1.9833 \end{bmatrix},$$

$$\mathbf{R} = \begin{bmatrix} 1.5625 & 1.5 \\ 1.5 & 1.5625 \end{bmatrix}$$

Στην Εικόνα 3-1 συνοψίζονται τα αποτελέσματα της συγκριτικής εξομοίωσης. Τα εκτιμώμενα στοιχεία των τελεστών  $\{\mathbf{A}_p, \mathbf{B}_q\}$  του μοντέλου καθώς και η τετραγωνική ρίζα του αντίστοιχου Μέσου Τετραγωνικού Λάθους (*root mean square error – RMS Error*) συνοψίζονται στον Πίνακα 3-1. Η Εικόνα 3-2 απεικονίζει την ακολουθία των εκ των υστέρων πιθανοτήτων που αντιστοιχούν σε κάθε μια από τις προτεινόμενες τιμές του  $\theta$ .



Εικ. 3-1. Παράδειγμα 1<sup>ο</sup>: Σύγκριση κριτηρίων

### Παρατήρηση:

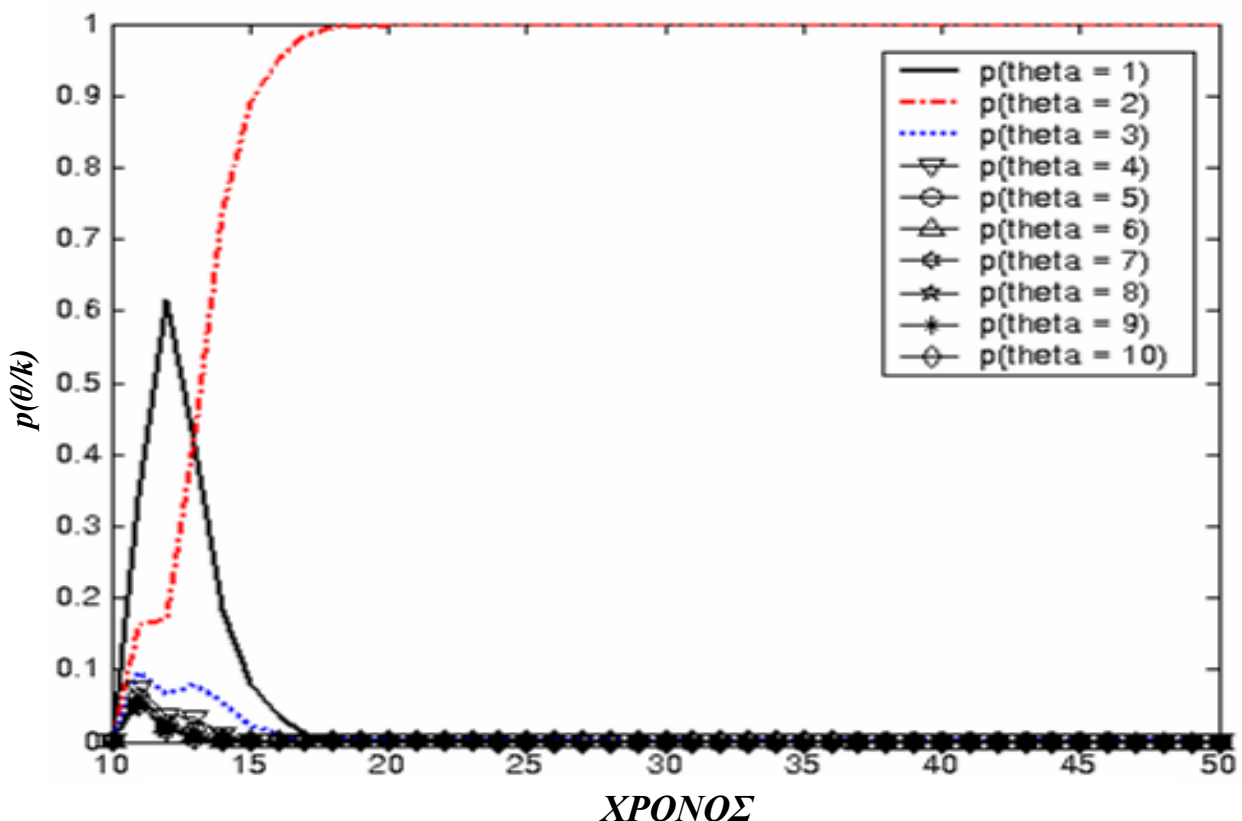
Στην εικόνα 3-2 ο οριζόντιος άξονας ξεκινά από την  $10^1$  χρονική στιγμή και όχι από το μηδέν. Αυτό συμβαίνει διότι η αρχική υπόθεση ήταν πως η άγνωστη τάξη του μοντέλου βρίσκεται στο διακριτό διάστημα  $[1, M]$ , όπου  $M = 10$ . Συνεπώς τα



πρώτα 10 δείγματα των αρχικών δεδομένων χρησιμοποιούνται για την αρχικοποίηση του αλγορίθμου. Το ίδιο ισχύει και για τα υπόλοιπα παραδείγματα που ακολουθούν.

Όπως προκύπτει από την *Εικόνα 3-1*, ο προτεινόμενος αλγόριθμος *MMPF* είναι 100% επιτυχής, (δηλαδή και για τα 100 *MCRs* εκτίμησε τη σωστή τάξη του μοντέλου, εδώ  $\theta = 2$ ) και για τα δυο σύνολα αρχικών δεδομένων, (το μικρότερο των 50, αλλά και για το μεγαλύτερο των 100). Την ίδια επιτυχή απόδοση έχει και το κριτήριο *BIC* για το μεγαλύτερο όμως σύνολο αρχικών δεδομένων.

Η *Εικόνα 3-2* απεικονίζει την ακολουθία των εκ των υστέρων πιθανοτήτων του φίλτρου Λαϊνιώτη, *MMPF*. Όπως είναι εμφανές το φίλτρο συγκλίνει πολύ γρήγορα στη σωστή τάξη του μοντέλου,  $\theta = 2$ , σε επτά μόνο βήματα. Ως κριτήριο σύγκλισης θεωρείται κάποια από τις εκ των υστέρων πιθανότητες να έχει τιμή μεγαλύτερη από 0.9.



Εικ. 3-2. Παράδειγμα 1<sup>ο</sup>. Ακολουθία των εκ των υστέρων πιθανοτήτων φίλτρου Λαϊνιώτη (*MMPF*)

<i>Πραγματικοί Τελεστές</i>	<i>Εκτιμώμενοι Τελεστές</i>	$\sqrt{\text{Μέσο Λάθος}}$
-0.85	-0.8459	0.0033
0.65	0.6508	0.0036
0.75	0.7501	0.0040
-0.55	0.5511	0.0032
-1.9833	-1.9823	0.0092
1.7	1.6089	0.0064
1.889	1.883	0.0074
1.9833	1.9799	0.0057

**Πίνακας 3-1.** Παράδειγμα 1<sup>ο</sup>: Πραγματικοί και Εκτιμώμενοι Τελεστές και η Τετραγωνική ρίζα του αντίστοιχου Μέσου Τετραγωνικού Λάθους (*Root Mean Square Error*)

**Παράδειγμα 2<sup>ο</sup>:** Μοντέλο MV ARMA (1, 1).  $\theta = (I, I) = 2$ ,  $M = 10$ . Αυτό το μοντέλο έχει αυξημένη πολυπλοκότητα σε σχέση με το προηγούμενο μιας και έχει διάσταση  $m = 3$ .

$$\mathbf{A} = \begin{bmatrix} 1 & 0.2 & 0.23 \\ 0.15 & 0.18 & 0.16 \\ 0.17 & 0.24 & 0.21 \end{bmatrix}, \mathbf{B} = \begin{bmatrix} 1 & 0.15 & 0.09 \\ 0.1 & -0.1 & 0.05 \\ 0.05 & 0.13 & 0.075 \end{bmatrix},$$

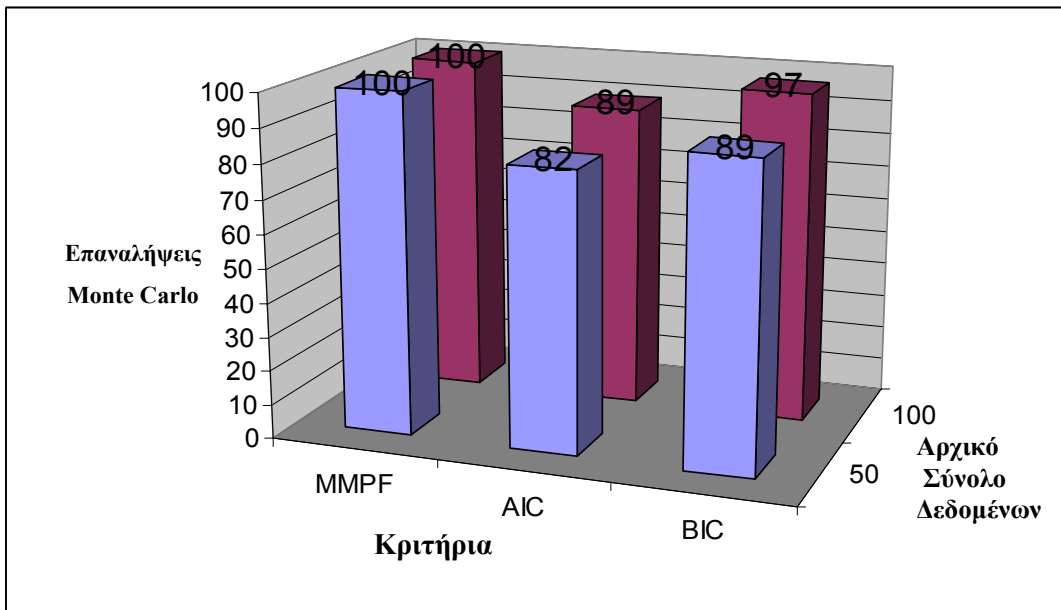
$$\mathbf{R} = \text{diag} [(0.42, 0.01, 0.16)].$$

Στην Εικόνα 3-3 συνοψίζονται τα αποτελέσματα της συγκριτικής εξομοίωσης. Τα εκτιμώμενα στοιχεία των τελεστών  $\{\mathbf{A}_p, \mathbf{B}_q\}$  του μοντέλου καθώς και η τετραγωνική ρίζα του αντίστοιχου Μέσου Τετραγωνικού Λάθους (*root mean square error – RMS Error*) συνοψίζονται στον Πίνακα 3-2. Η Εικόνα 3-4 απεικονίζει την ακολουθία των εκ των υστέρων πιθανοτήτων που αντιστοιχούν σε κάθε μια από τις προτεινόμενες τιμές του  $\theta$ .


Η Εικόνα 3-4 δείχνει ότι φίλτρο Λαϊνιώτη *MMPF*, είναι ικανό να αναγνωρίσει και πάλι την τάξη του μοντέλου αρκετά γρήγορα, μέσα σε οκτώ βήματα. Ως κρι-

τήριο σύγκλισης θεωρείται κάποια από τις εκ των υστέρων πιθανότητες να έχει τιμή μεγαλύτερη από 0.9.

Επίσης από την Εικόνα 3-3 είναι προφανές πως το *MMPF* είναι το μόνο κριτήριο που, σε αυτό το μοντέλο με την αυξημένη πολυπλοκότητα, επιτυγχάνει τη σωστή επιλογή της τάξης και για τα δυο σύνολα αρχικών δεδομένων.



Εικ. 3-3. Παράδειγμα 2<sup>ο</sup>: Σύγκριση κριτηρίων



Εικ. 3-4. Παράδειγμα 2<sup>ο</sup>. Ακολουθία των εκ των υστέρων πιθανοτήτων φίλτρου Λαϊνιώτη

<i>Πραγματικοί Τελεστές</i>	<i>Εκτιμώμενοι Τελε- στές</i>	$\sqrt{\text{Μέσο Λάθος}}$
1	0.9932	0.0152
0.2	0.2023	0.0035
0.23	0.2310	0.0021
0.15	0.1519	0.0143
0.18	0.1829	0.0091
0.16	0.1612	0.0044
0.17	0.1702	0.0030
0.24	0.2408	0.0371
0.21	0.2143	0.0045
1	1.0217	0.0026
0.15	0.1516	0.0016
0.09	0.0894	0.0059
0.1	0.1013	0.0023
-0.1	-0.1027	-0.0127
0.05	0.0059	0.0019
0.05	-0.0048	0.0017
0.13	0.1351	0.0046
0.075	0.0742	0.0028

**Πίνακας 3-2.** Παράδειγμα 2<sup>ο</sup>: Πραγματικοί και Εκτιμώμενοι Τελεστές και η Τετραγωνική ρίζα του αντίστοιχου Μέσου Τετραγωνικού Λάθους (*Root Mean Square Error*)

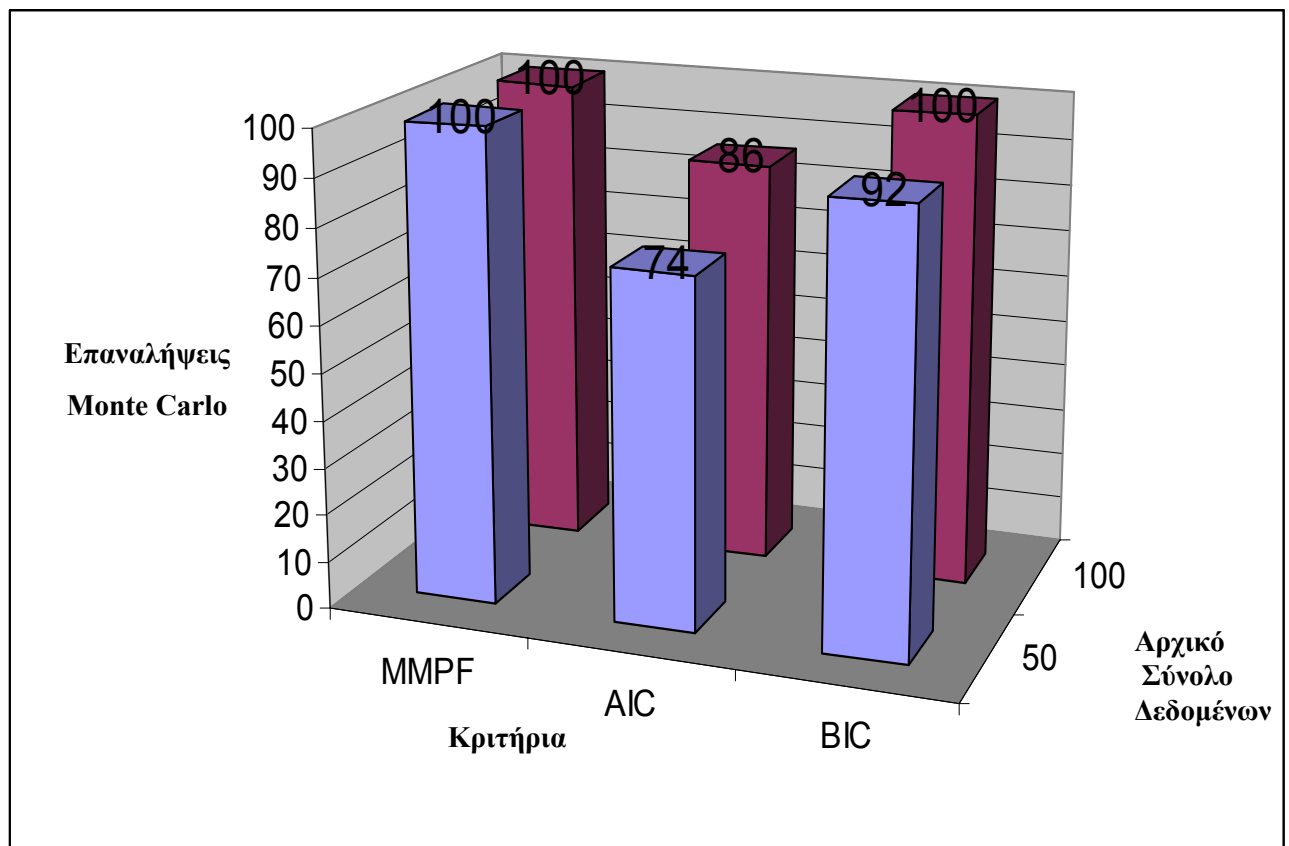
**Παράδειγμα 3<sup>ο</sup>:** Μοντέλο MV ARMA (2, 2).  $\theta = (2, 2) = 4$ ,  $M = 10$ .

$$\mathbf{A}_1 = \begin{bmatrix} -0.17 & 0.14 \\ -0.19 & -0.1 \end{bmatrix}, \mathbf{A}_2 = \begin{bmatrix} -0.2 & 0.12 \\ 0.22 & -0.25 \end{bmatrix},$$


$$\mathbf{B}_1 = \begin{bmatrix} -0.45 & 0.52 \\ -0.32 & -0.7 \end{bmatrix}, \mathbf{B}_2 = \begin{bmatrix} -0.85 & 0.75 \\ -0.65 & -0.55 \end{bmatrix},$$

$$\mathbf{R} = \begin{bmatrix} 1 & -0.08 \\ -0.08 & 1 \end{bmatrix}.$$

Το *MMPF* είναι το μοναδικό από τα τρία κριτήρια το οποίο είναι σε θέση να αναγνωρίσει σωστά την αθροιστική τάξη του μοντέλου και για τα δυο σύνολα αρχικών δεδομένων, (Εικόνα 3-5), και το κάνει αυτό πολύ γρήγορα καθώς 18 βήματα είναι αρκετά (Εικόνα 3-6). Το κριτήριο *BIC* έχει το ίδιο απόλυτο ποσοστό επιτυχίας αλλά για το μεγαλύτερο αρχικό σύνολο δεδομένων, καθώς για το μικρότερο η επίδοσή του υπολείπεται του *MMPF* κατά 8% (Εικόνα 3-5). Από τον Πίνακα 3-3 βλέπουμε πως και στην εκτίμηση των παραμέτρων το μέσο τετραγωνικό λάθος είναι πολύ μικρό.



Εικ. 3-5. Παράδειγμα 3<sup>ο</sup> : Σύγκριση κριτηρίων



Εικ. 3-6. Παράδειγμα 3°. Ακολουθία των εκ των υστέρων πιθανοτήτων φίλτρου Λαϊνιώτη (*MMPF*)

**Παράδειγμα 4<sup>ο</sup>** : Το παράδειγμα αυτό έχει σκοπό να δείξει ότι το φίλτρο Λαϊνιώτη, *MMPF*, είναι ικανό να εντοπίζει τις όποιες αλλαγές στην τάξη του μοντέλου σε πραγματικό χρόνο (*real time*). Σε κάθε βήμα ο αλγόριθμος επιλέγει ως λύση στο πρόβλημα εκείνο το μοντέλο που αντιστοιχεί στην υψηλότερη εκ των υστέρων πιθανότητα. Αυτή η πιθανότητα τείνει ασυμπτωτικά στη μονάδα ενώ οι εναπομείνουσες τείνουν στο μηδέν. Ο αλγόριθμος μπορεί να θεωρηθεί προσαρμοζόμενος (*adaptive*) με την έννοια ότι μπορεί να εντοπίσει τις αλλαγές της τάξης του μοντέλου σε πραγματικό χρόνο.

<i>Πραγματικοί Τελεστές</i>	<i>Εκτιμώμενοι Τελε- στές</i>	$\sqrt{\text{Μέσο Λάθος}}$
-0.17	-0.1691	0.0047
-0.19	-0.1896	0.0054
0.14	0.1458	0.0137
-0.1	-0.0899	0.0161
-0.2	-0.1982	0.0064
0.22	0.2234	0.0073
0.12	0.1154	0.0094
-0.25	-0.2573	0.0114
-0.45	-0.4535	0.0094
-0.32	-0.3260	0.0109
0.52	0.5244	0.0090
-0.7	-0.6931	0.0108
-0.85	-0.8441	0.0122
-0.65	-0.6407	0.0147
0.75	0.7508	0.0086
-0.55	-0.5471	0.0094

**Πίνακας 3-3:** Παράδειγμα 3<sup>0</sup>: Πραγματικοί και Εκτιμώμενοι Τελεστές και η Τετραγωνική ρίζα του αντίστοιχου Μέσου Τετραγωνικού Λάθους (*Root Mean Square Error*)

Ο Πίνακας 3-4 παρουσιάζει το σύνολο αρχικών δεδομένων.

<b>Βήματα</b>	<b>Τάξη <math>\theta</math></b>	<b>Βήματα</b>	<b>Τάξη <math>\theta</math></b>
1 – 40	3	121 – 160	3
41- 80	4	161 – 200	4
81 - 120	2		

**Πίνακας 3-4.** Μεταβολή της τάξης  $\theta$  του μοντέλου σε σχέση με το χρόνο

Τα τρία *MV ARMA* μοντέλα που χρησιμοποιήθηκαν για το σκοπό αυτής της εξομοίωσης είναι εκείνα των *Παραδειγμάτων 1* και *3* καθώς και το ακόλουθο:

$$\mathbf{A}_1 = \begin{bmatrix} 0.6 & 0 \\ 0.5 & -0.5 \end{bmatrix}, \mathbf{A}_2 = \begin{bmatrix} 0.8 & -0.2 \\ 0.3 & -0.1 \end{bmatrix},$$

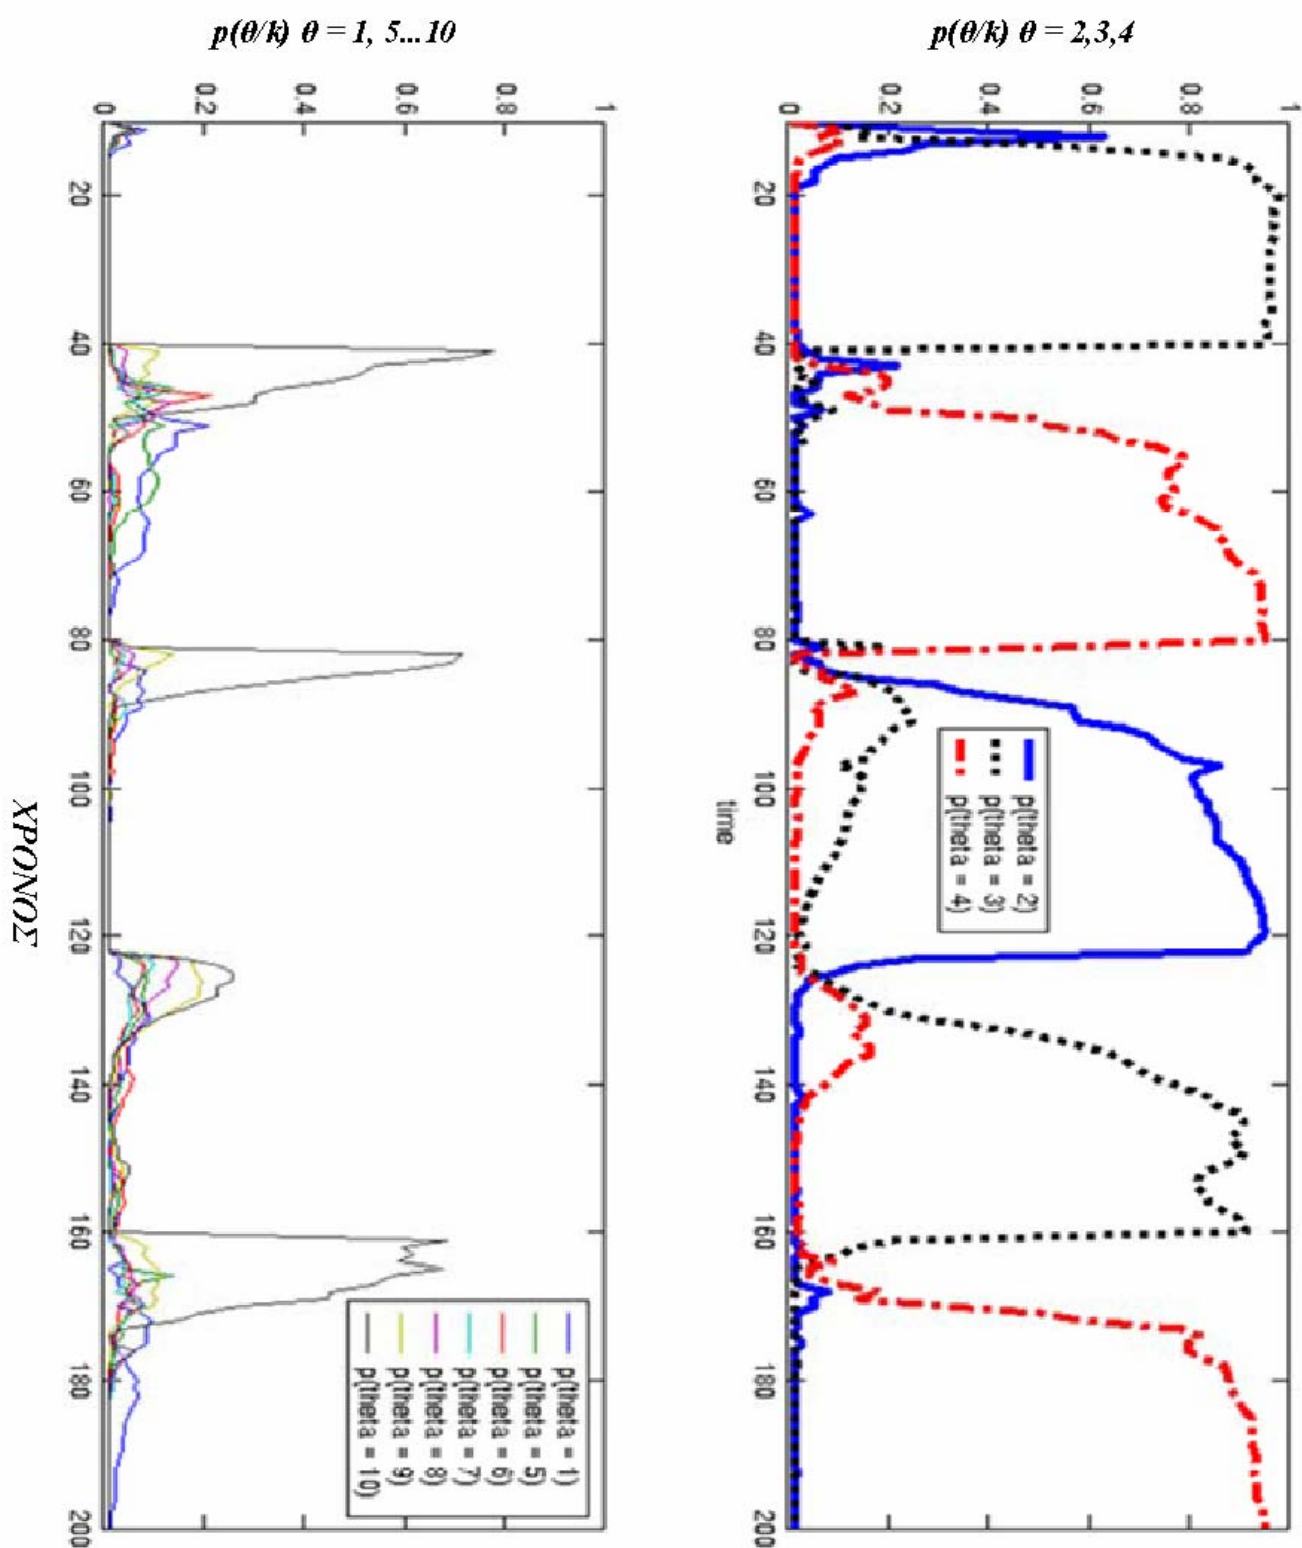
$$\mathbf{B}_1 = \begin{bmatrix} -0.85 & -0.8 \\ 0.1 & 0.23 \end{bmatrix}$$

Η μήτρα διασποράς του θορύβου  $\mathbf{R}$  είναι  $\begin{bmatrix} 1 & -0.08 \\ -0.08 & 1 \end{bmatrix}$  και  $M = 10$ .

Όπως και σε όλα τα προηγούμενα παραδείγματα έτσι και εδώ πραγματοποιήθηκαν 100 *MCRs*. Όπως προκύπτει από την *Εικόνα 3-7* το φίλτρο Λαϊνιώτη *MMPF*, αναγνωρίζει με επιτυχία τη σωστή τάξη του μοντέλου (η αντίστοιχη εκ των υστέρων πιθανότητα έχει τιμή μεγαλύτερη από 0.9). Κάθε φορά που συμβαίνει αλλαγή στην τάξη  $\theta$  του μοντέλου το φίλτρο Λαϊνιώτη *MMPF*, χρειάζεται  $M$  βήματα (στην εξεταζόμενη περίπτωση  $M = 10$ ) για την αρχικοποίηση των χρησιμοποιούμενων μεταβλητών. Αυτός είναι και ο λόγος που υπάρχει μια καθυστέρηση 10 βημάτων πριν το φίλτρο αρχίσει να συγκλίνει στο σωστό μοντέλο αυξάνοντας την αντίστοιχη εκ των υστέρων πιθανότητα (*Εικόνα 3-7*). Η αρχικοποίηση αυτή γίνεται αυτόματα χωρίς να χρειάζεται η παρέμβαση του χρήστη [47].

**Παράδειγμα 5<sup>ο</sup>** : Το παράδειγμα αυτό έχει σκοπό να δείξει ότι το φίλτρο Λαϊνιώτη, *MMPF*, είναι ικανό να εντοπίζει τις όποιες αλλαγές στην τάξη του μοντέλου σε πραγματικό χρόνο (*real time*) ακόμα και όταν η πολυπλοκότητα των μοντέλων αυξάνεται, δηλαδή χρησιμοποιώντας διάσταση  $m = 3$ . Και σε αυτήν την περίπτωση όπως και στο προηγούμενο παράδειγμα ο αλγόριθμος επιλέγει ως λύση στο πρόβλημα σε κάθε βήμα εκείνο το μοντέλο που αντιστοιχεί στην υψηλότερη εκ των υστέρων πιθανότητα. Αυτή η πιθανότητα τείνει ασυμπτωτικά στη μονάδα ενώ οι εναπομείνουσες τείνουν στο μηδέν (*Εικόνα 3-8*). Ο αλγόριθμος μπορεί να θεωρηθεί προσαρμοζόμενος (*adaptive*) με την έννοια ότι μπορεί να εντοπίσει τις αλλαγές της τάξης του μοντέλου σε πραγματικό χρόνο [96].





Εικ. 3-7. Παράδειγμα 4<sup>ο</sup>: Ακολουθία των εκ των υστέρων πιθανοτήτων φίλτρου Λαϊνιώτη (MMPF)

Ο Πίνακας 3-5 παρουσιάζει το σύνολο αρχικών δεδομένων.

Βήματα	Τάξη $\theta$	Βήματα	Τάξη $\theta$
1 – 40	3	121 – 160	3
41- 80	4	161 – 200	4
81 - 120	2		

Πίνακας 3-5. Μεταβολή της τάξης  $\theta$  του μοντέλου σε σχέση με το χρόνο

Τα τρία *MV ARMA* μοντέλα που χρησιμοποιήθηκαν για το σκοπό αυτής της εξομοίωσης είναι τα ακόλουθα:

1. ARMA (1, 1).  $\theta = (1, 1) = 2$ .

$$\mathbf{A}_1 = \begin{bmatrix} -0.9 & 0.8 & 0.6 \\ 0.66 & -0.55 & 0.45 \\ 0.58 & 0.49 & 0.37 \end{bmatrix}, \mathbf{B}_1 = \begin{bmatrix} -1.97 & 1.86 & 1.5 \\ 1.72 & 1.92 & 0.98 \\ 1.48 & 0.95 & 0.67 \end{bmatrix}$$

2. ARMA (2, 1).  $\theta = (2, 1) = 3$ .

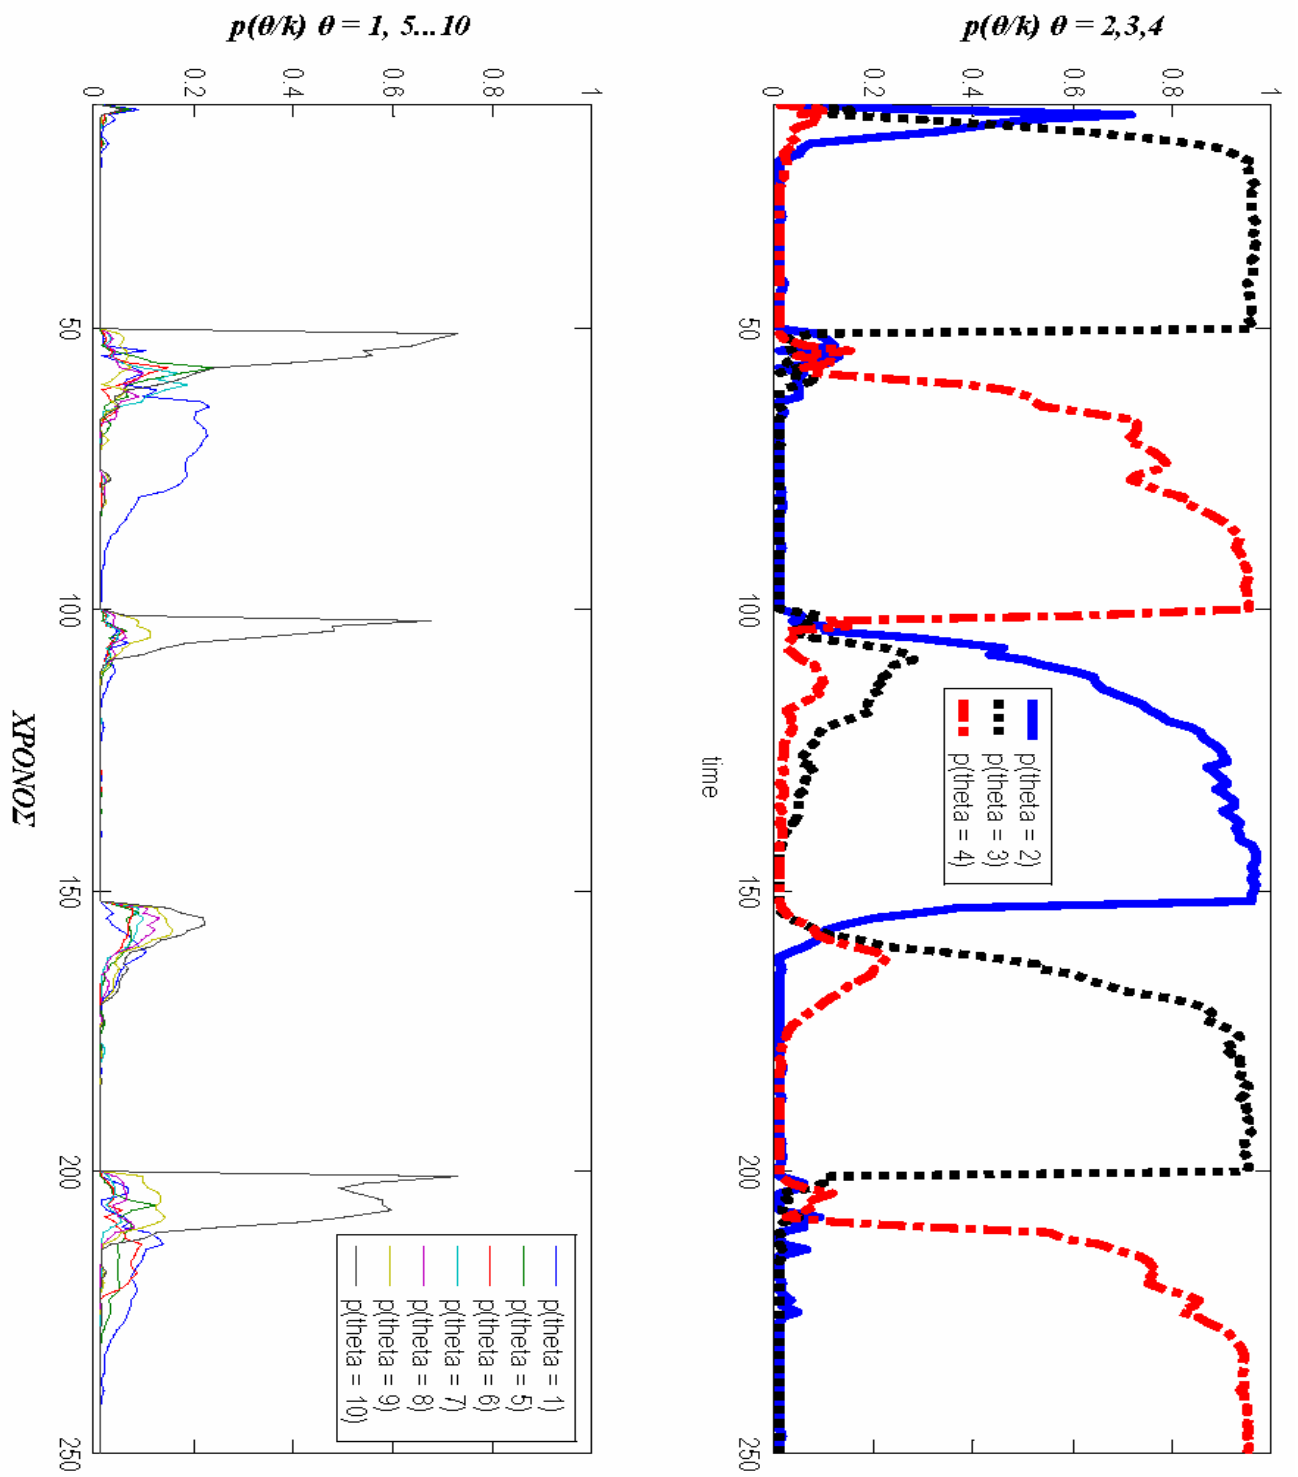
$$\mathbf{A}_1 = \begin{bmatrix} 0.79 & 0.3 & 0.21 \\ 0.21 & 0.38 & 0.12 \\ 0.19 & 0.14 & 0.23 \end{bmatrix}, \mathbf{A}_2 = \begin{bmatrix} 1 & 0.89 & 0.32 \\ 0.45 & 0.50 & 0.26 \\ 0.28 & 0.34 & 0.87 \end{bmatrix}, \mathbf{B}_1 = \begin{bmatrix} 1 & 0.22 & 0.9 \\ -0.1 & 0.1 & 0.07 \\ 0.04 & 0.33 & 0.085 \end{bmatrix}.$$

3. ARMA (2, 2).  $\theta = (2, 2) = 4$ , with  $m = 3$ .

$$\mathbf{A}_1 = \begin{bmatrix} -0.21 & 0.16 & 0.34 \\ -0.23 & -0.11 & 0.01 \\ 0.4 & 0.05 & 0.42 \end{bmatrix}, \mathbf{A}_2 = \begin{bmatrix} -0.19 & 0.13 & 0.4 \\ 0.21 & -0.24 & 0.02 \\ 0.3 & 0.06 & 0.17 \end{bmatrix}$$

$$\mathbf{B}_1 = \begin{bmatrix} -0.42 & 0.53 & 0.19 \\ -0.31 & -0.6 & 0.81 \\ 0.7 & 0.05 & 0.4 \end{bmatrix}, \mathbf{B}_2 = \begin{bmatrix} -0.82 & 0.71 & 0.63 \\ -0.65 & -0.55 & 0.42 \\ 0.41 & 0.37 & 0.24 \end{bmatrix},$$

Η μήτρα διασποράς του θορύβου  $\mathbf{R}$  είναι  $\text{diag} [(0.42, 0.01, 0.16)] \times \mathbf{I} (3 \times 3)$  και  $M = 10$ .



Εικ. 3-8. Παράδειγμα 4<sup>ο</sup>: Ακολουθία των εκ των υστέρων πιθανοτήτων φίλτρου Λαϊνιώτη (MMPF)

### 3.5. Συμπεράσματα

Ο αλγόριθμος της επιλογής της τάξης και εκτίμησης των συντελεστών  $MV AR$  μοντέλων, επεκτάθηκε και εφαρμόστηκε για τον ίδιο σκοπό σε  $MV ARMA$  μοντέλα.

Η προτεινόμενη μέθοδος επιλέγει με επιτυχία τη σωστή, αθροιστικά, τάξη του μοντέλου σε πολύ μικρό χρόνο και αναγνωρίζει με μεγάλη ακρίβεια τους τελεστές των  $MV ARMA$  μοντέλων που δοκιμάστηκαν. Επίσης έγινε σύγκριση του προτεινόμενου αλγόριθμου με άλλα δυο καταξιωμένα κριτήρια επιλογής της τάξης  $MV ARMA$  μοντέλων, συγκεκριμένα  $AIC$ , και  $BIC$ , μέσω της οποίας αποδεικνύεται ότι μπορεί να δώσει λύση και στα δυο προβλήματα χρησιμοποιώντας πάντα το μικρότερο αρχικό σύνολο δεδομένων, ενώ το πιο ανταγωνιστικό κριτήριο  $BIC$  χρειάζεται το μεγαλύτερο αριθμό αρχικών δεδομένων όταν η τάξη ή πολυπλοκότητα του μοντέλου αυξάνει. Συμπληρωματικά η μέθοδος αποδείχθηκε ότι μπορεί να εντοπίσει τυχόν αλλαγές της τάξης του μοντέλου  $\theta$  σε πραγματικό χρόνο ακόμα και όταν η πολυπλοκότητα των μοντέλων αυξάνεται.

## **Κεφάλαιο 4**

Μοντελοποίηση και Εκτίμηση της Διακύμανσης  
της Ζήτησης του Ηλεκτρικού Φορτίου του  
Ελληνικού Δικτύου Ηλεκτρικής Ενέργειας

## 4.1. Εισαγωγή

**Α**πό τα απαιτητικότερα ζητήματα στον τομέα της ενέργειας είναι η διαχείριση της αστάθειας στη ζήτηση του ηλεκτρικού φορτίου. Εκτός του γεγονότος ότι η αστάθεια αυτή καταπονεί το ίδιο το δίκτυο μεταφοράς, έχει και σημαντική επίπτωση στον οικονομικό τομέα αφού μπορεί να επηρεάσει τόσο την τρέχουσα τιμή της ηλεκτρικής μονάδας όσο και τις μακροπρόθεσμες επενδύσεις αναφορικά με την αναβάθμιση του συνολικού δικτύου παραγωγής και μεταφοράς της ηλεκτρικής ενέργειας. Όταν έχουμε να κάνουμε με τον τομέα της ενέργειας είναι καλό να έχουμε στο μυαλό μας πως η ηλεκτρική ενέργεια δεν είναι δυνατό να παραχθεί, μεταφερθεί και παραδοθεί με το πάτημα ενός κουμπιού. Επίσης είναι ένα αγαθό που δεν μπορεί να αποθηκευθεί, όπως ενδεχομένως το πετρέλαιο, γεγονός που καθιστά οριακή την ισορροπία μεταξύ των δύο άκρων του συστήματος, δηλαδή την παραγωγή και τη ζήτηση. Σχετικά μικρές αλλαγές στη ζήτηση ή στην παραγωγή ηλεκτρικής ενέργειας μπορούν να προκαλέσουν συγκριτικά πολύ μεγαλύτερες αλλαγές στην τιμή της ηλεκτρικής μονάδας μέσα σε λίγες ώρες ή ακόμα και λεπτά. Με αυτό το σκεπτικό η αγορά της ηλεκτρικής ενέργειας είναι ένα πολύ ιδιόμορφο πεδίο.

Στο κεφάλαιο αυτό διερευνάται το πρόβλημα της αποτελεσματικής παραμετροποίησης, μοντελοποίησης και εκτίμησης της ζήτησης του ηλεκτρικού φορτίου χρησιμοποιώντας μοντέλα ARMA. Τα δεδομένα είναι πραγματικά και μας χορηγήθηκαν ευγενικά από τη Δ.Ε.Η. Α.Ε. [97]. Όπως θα αποδειχτεί στο πρώτο μέρος του κεφαλαίου, υπάρχει η δυνατότητα εφαρμογής μοντέλων ARMA στα υπάρχοντα δεδομένα με την προϋπόθεση ότι αυτά προηγουμένως έχουν υποβληθεί σε ειδική επεξεργασία, *off-line*, η οποία τους αφαιρεί την περιοδικότητα. Στη συνέχεια θα μελετηθεί και η εφαρμογή μοντέλων SARIMA τα οποία χρησιμοποιούν τα πραγματικά δεδομένα χωρίς προεπεξεργασία. Στη βιβλιογραφία υπάρχει αρκετή έρευνα στον τομέα μοντελοποίησης και εκτίμησης της ζήτησης του ηλεκτρικού φορτίου ειδικά μετά την εισαγωγή της αγοράς της ηλεκτρικής ενέρ-


γειας στο χρηματιστήριο. Πολλές μέθοδοι έχουν προταθεί και υλοποιηθεί για τη λύση του προαναφερθέντος προβλήματος χρησιμοποιώντας μοντέλα όπως *οικονομετρικά (econometric)* [98], *neuro – fuzzy* [99], *AR* [100], *ARIMA* [101-104], *ARMA* [105-107] Έχουν επίσης χρησιμοποιηθεί μέθοδοι όπως *γραμμική παλινδρόμηση (linear regression)* [108], *τεχνητή νοημοσύνη (artificial intelligence)* [109, 110], *εξόρυξη δεδομένων (data mining)* [111], κ.α.

Το αμέσως επόμενο ερώτημα είναι πόσο αξιοποιήσιμο μπορεί να είναι ένα μοντέλο ARMA όταν τα δεδομένα περιέχουν υψηλό θόρυβο ή όταν χρειάζεται *on – line* μοντελοποίηση. Στο ερώτημα αυτό απαντά η σύγκριση τριών καταξιωμένων κριτηρίων σχετικά με την επιτυχή αναγνώριση της τάξης και των συντελεστών του υπάρχοντος μοντέλου ARMA υπό την επίδραση υψηλού θορύβου. Ονομαστικά τα κριτήρια αυτά είναι τα *Corrected Akaike Criterion (AICC)*, *Akaike’s Information Criterion (AIC)*, *Bayesian Information Criterion (BIC)* και τέλος ο Αλγόριθμος πολυ-μοντελικού Διαμελισμού (ή φίλτρο Λαϊνιώτη) *MMPF*. Στη συνέχεια ερευνάται ποιες από τις μεθόδους που χρησιμοποιήθηκαν μπορούν να εκτιμήσουν τη διακύμανση του ηλεκτρικού φορτίου για μια εβδομάδα χωρίς να υπερβούν ένα συγκεκριμένο όριο λάθους, (2.5%). Στα συγκρινόμενα κριτήρια αυτή τη φορά προστίθενται και τα Τεχνητά Νευρωνικά Δίκτυα (*Artificial Neural Networks-ANN*). Εκτεταμένη αναφορά για τη χρησιμοποίηση των νευρωνικών δικτύων στις γραμμές μεταφοράς ηλεκτρικής ενέργειας μπορεί να βρεθεί στα [112-114]. Επιπλέον πραγματοποιείται η εκτίμηση της ημερήσιας μέγιστης ζήτησης φορτίου (*daily peak forecast*). Στο τελικό στάδιο παρουσιάζεται η χρησιμοποίηση των πραγματικών δεδομένων με σκοπό τη μοντελοποίηση της ζήτησης του ηλεκτρικού φορτίου μέσω ενός μοντέλου *SARIMA*. Η μέθοδος πολυμοντελικού διαμελισμού εφαρμόζεται και πάλι με στόχο την αναγνώριση ενός μοντέλου που θα περιγράφει τη διακύμανση του φορτίου και θα είναι ικανό να εντοπίζει πιθανές μη περιοδικές ανωμαλίες όπως υψηλή ζήτηση (*peak load*) ή σφάλμα στη γραμμή (*blackout*). Τα συμπεράσματα αυτής της έρευνας μπορούν να αξιοποιηθούν στην

περαιτέρω μελέτη της διακύμανσης του ηλεκτρικού φορτίου καθώς και στην πρόβλεψη της τιμής της ηλεκτρικής μονάδας.

## 4.2. Προετοιμασία των Δεδομένων.


Τα στοιχεία που χρησιμοποιούνται στο τμήμα αυτό της έρευνας και αφορούν το ηλεκτρικό φορτίο μας χορηγήθηκαν ευγενικά από τη Δ.Ε.Η Α.Ε [97] και περιλαμβάνουν την ημερήσια ζήτηση ηλεκτρικού φορτίου από 1<sup>η</sup> Ιανουαρίου 2004 έως και την 31<sup>η</sup> Δεκεμβρίου 2005. Οι εικόνες 4-1 και 4-2 δείχνουν την εμφανή περιοδικότητα των δεδομένων τόσο σε ετήσια όσο και σε εβδομαδιαία βάση.



**Εικ. 4-1.** Ζήτηση Ηλεκτρικού Φορτίου από 1<sup>η</sup> Ιανουαρίου 2004 έως την 31<sup>η</sup> Δεκεμβρίου 2005. Η ετήσια και η εβδομαδιαία περιοδικότητα καθώς και η συνεχόμενα αυξανόμενη ζήτηση είναι εμφανείς.




Το πρώτο απαραίτητο βήμα που θα πρέπει κάποιος να ακολουθήσει σε αυτήν την περίπτωση είναι η απομάκρυνση της περιοδικότητας. Αυτό επιτυγχάνεται εφαρμόζοντας στα δεδομένα μια νέα τεχνική η οποία παρουσιάστηκε και περιγράφεται αναλυτικά από τους Nowicka-Zagrajek και Weron [106, 107]. Επίσης στο τμήμα αυτό της έρευνας χρησιμοποιήθηκε και το εργαλείο του MATLAB<sup>®</sup> *Modeling and Forecasting Electricity Loads and Prices (MFE)*, το οποίο είναι ελεύθερο για δημόσια χρήση [115].



**Εικ. 4-2.** Περιοδικό γράφημα της ζήτησης του ηλεκτρικού φορτίου από 1<sup>η</sup> Ιανουαρίου 2004 έως την 31<sup>η</sup> Δεκεμβρίου 2005. Η ετήσια και η εβδομαδιαία περιοδικότητα είναι εμφανείς καθώς παρουσιάζουν πολύ υψηλές συχνότητες.


Έπειτα από τη χρησιμοποίηση της προαναφερθείσας μεθόδου [106, 107, 115] προέκυψε η χρονική σειρά που φαίνεται στις Εικόνες 4-3 και 4-4.

Συγκρίνοντας τα διαγράμματα 4-1 και 4-3 καθώς και τα 4-2, 4-4 μπορούμε να πούμε ότι από τα αρχικά δεδομένα έχει απομακρυνθεί η περιοδικότητα και η νέα χρονική σειρά θα μπορούσε να θεωρηθεί ως πραγμάτωση μιας στάσιμης διεργασίας.




**Εικ.4-3.** Ζήτηση Ηλεκτρικού Φορτίου από 1<sup>η</sup> Ιανουαρίου 2004 έως την 31<sup>η</sup> Δεκεμβρίου 2005, έπειτα από τη διεργασία απομάκρυνσης της ετήσιας και της ετήσιας περιοδικότητας.


Επιπρόσθετα τόσο η Συνάρτηση Αυτοσυσχέτισης (*Auto Correlation Function - ACF*) όσο και η Συνάρτηση Μερικής Αυτοσυσχέτισης (*Partial Auto Correlation Function - PACF*) τείνουν πολύ γρήγορα στο μηδέν, Εικόνες 4-5 και 4-6, γεγονός που υποδηλώνει ότι η προκύπτουσα χρονική σειρά θα μπορούσε να μοντελοποιηθεί χρησιμοποιώντας μια διεργασία τύπου *ARMA*.



**Εικ. 4-4.** Περιοδικό γράφημα της ζήτησης του ηλεκτρικού φορτίου από την 1<sup>η</sup> Ιανουαρίου 2004 έως την 31<sup>η</sup> Δεκεμβρίου 2005 μετά από την απομάκρυνση της ετήσιας και της εβδομαδιαίας περιοδικότητας. Είναι εμφανές ότι δεν παρατηρείται κάποια δεσπόζουσα (*dominating*) συχνότητα.



**Εικ. 4-5.** Συνάρτηση Αυτοσυσχέτισης (*ACF*) για τα επεξεργασμένα δεδομένα, χωρίς περιοδικότητα. Οι διακεκομμένες γραμμές αναπαριστούν τα επιτρεπόμενα όρια διακύμανσης ( $\pm 1.96/\sqrt{730}$ ).



(Time Lag) Χρονική Υστέρηση (Ημέρες)

Εικ. 4-6. Συνάρτηση Μερικής Αυτοσυσχέτισης (*PACF*) για τα επεξεργασμένα δεδομένα, χωρίς περιόδικότητα. Οι γραμμές αναπαριστούν τα επιτρεπόμενα όρια διακύμανσης ( $\pm 1.96/\sqrt{730}$ ).

### 4.3. Μοντελοποίηση των επεξεργασμένων δεδομένων μέσω διεργασίας τύπου ARMA.

Η περιγραφή και η αναλυτική εξήγηση των μοντέλων *ARMA*, έχει ήδη γίνει στο κεφάλαιο 3. Αυτό που θα επαναλάβουμε εδώ είναι πως η εκτίμηση της τάξης του μοντέλου είναι από τα σημαντικά βήματα στην προσπάθεια μοντελοποίησης δεδομένων.

Στο σημείο αυτό της έρευνας τα επεξεργασμένα δεδομένα εισήχθησαν και υπέστησαν επεξεργασία *off-line*, στο λογισμικό εργαλείο του MATLAB® *Modeling and Forecasting Electricity Loads and Prices (MFE)* [115], με σκοπό την εύρεση ενός μοντέλου ARMA. Το λογισμικό αυτό εργαλείο για τον προαναφερθέντα

σκοπό χρησιμοποιεί το *Akaike's Corrected Information Criterion (AICC)* και ουσιαστικά ελαχιστοποιεί την παρακάτω συνάρτηση:

$$AICC = \log |\hat{\mathbf{R}}_0| + \frac{2(p+q+1)n}{n-p-q-2} \quad (4-1)$$

όπου  $n = 730$ , και είναι το πλήθος των δεδομένων που χρησιμοποιούμε,  $\theta (p, q)$  συμβολίζει την τάξη του μοντέλου και τέλος  $\hat{\mathbf{R}}_0$  είναι η μέγιστη πιθανή εκτίμηση (*maximum likelihood estimate*) του  $\mathbf{R}$ , (εξίσωση 3-3), υπό την προϋπόθεση ότι  $\theta$  είναι η πραγματική τάξη του μοντέλου.

Το μοντέλο το οποίο προέκυψε έχει την ακόλουθη δομή, σύμφωνα με την εξίσωση (3-3):

$$\mathbf{A}_1 = [-0.3153], \mathbf{A}_2 = [0.0287], \mathbf{B}_1 = [-0.1363], \mathbf{B}_2 = [0.1985], \mathbf{B}_3 = [0.1604], \mathbf{B}_4 = [0.4057], \mathbf{B}_5 = [0.4211], \mathbf{B}_6 = [0.2417].$$


$$\mathbf{Y}_t = \mathbf{A}_1 \mathbf{Y}_{t-1} + \mathbf{A}_2 \mathbf{Y}_{t-2} + \mathbf{B}_1 \mathbf{v}_{k-1} + \mathbf{B}_2 \mathbf{v}_{k-2} + \mathbf{B}_3 \mathbf{v}_{k-3} + \mathbf{B}_4 \mathbf{v}_{k-4} + \mathbf{B}_5 \mathbf{v}_{k-5} + \mathbf{B}_6 \mathbf{v}_{k-6}. \quad (4-2)$$

Η τιμή για το κριτήριο *AICC* σύμφωνα πάντα με το λογισμικό εργαλείο που χρησιμοποιήθηκε είναι  $AICC = 1821.362$ .

Το επόμενο βήμα είναι ο έλεγχος του παραπάνω μοντέλου, (4-2), με σκοπό να διαπιστωθεί εάν η συμπεριφορά του ταιριάζει με εκείνη των επεξεργασμένων δεδομένων.

Αν λοιπόν το μοντέλο που περιγράφεται στην εξίσωση (4-2) είναι το καταλληλότερο τότε η συμπεριφορά του θα πρέπει να είναι ανάλογη μιας ανεξάρτητης και ταυτοτικής κατανομής (*independent and identical distribution iid*). Στην παρούσα περίπτωση μια τέτοια συμπεριφορά μπορεί εύκολα να αναπαρασταθεί από μια ακολουθία θορύβου (*noise sequence*) μέσης τιμής  $\theta$  και απόκλισης  $\sigma^2$  διότι μια τέτοια ακολουθία είναι από τα πιο χαρακτηριστικά παραδείγματα ανεξάρτητης και ταυτοτικής κατανομής, Εικ. 4-7.

Από τον έλεγχο λοιπόν του μοντέλου που σχεδιάστηκε (4-2) προέκυψαν τα ακόλουθα συμπεράσματα:




**Εικ 4-7.** Συμπεριφορά ακολουθίας θορύβου. Όπως είναι εμφανές δεν υπάρχει κάποιο ίχνος περιοδικότητας. Θα μπορούσε να είναι και η έξοδος ενός μοντέλου ARMA.

Η συμπεριφορά του μοντέλου, όπως αυτή φαίνεται από την Εικ 4-8, φαίνεται να ταιριάζει με την επιδιωκόμενη Εικ 4-3, και επίσης δεν παρουσιάζει ίχνη μη μηδενικής μέσης τιμής (*non zero mean value*) ή μη σταθερής απόκλισης (*non-constant variance*).

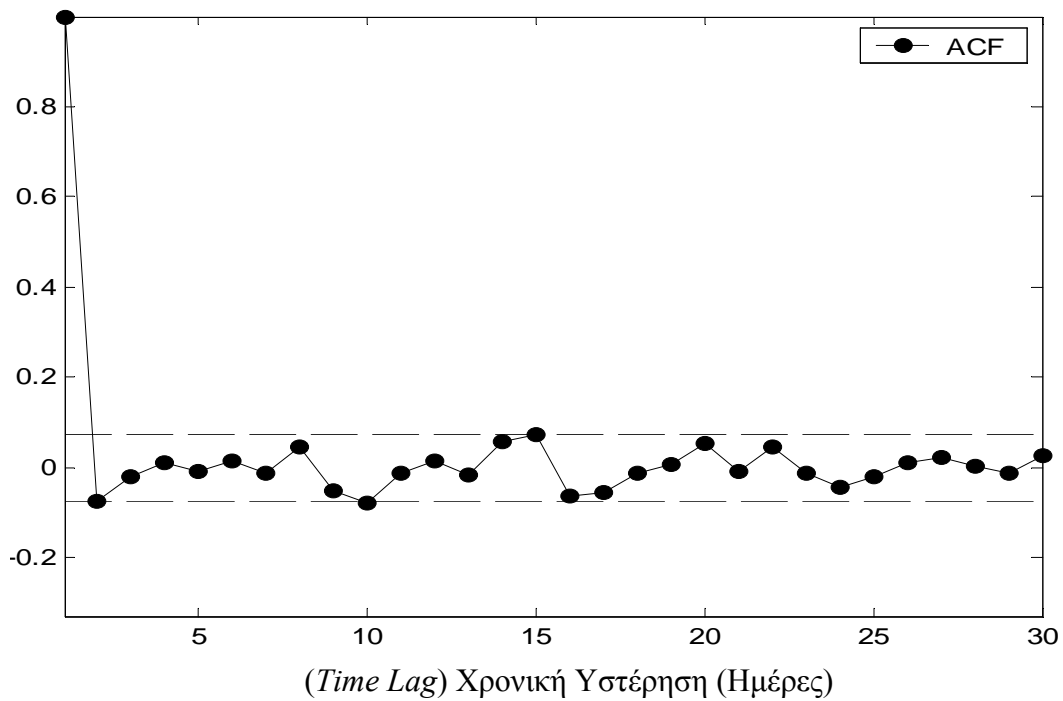
Επιπρόσθετα τόσο η Συνάρτηση Αυτοσυσχέτισης όσο και η Συνάρτηση Μερικής Αυτοσυσχέτισης τείνουν πολύ γρήγορα στο μηδέν μέσα στα επιτρεπτά όρια, Εικόνες 4-9 και 4-10, γεγονός που υποδηλώνει ότι δεν υπάρχει συσχέτιση μεταξύ των δεδομένων.

Συνεπώς για το μοντέλο που προέκυψε (4-2), δε συντρέχει λόγος απόρριψης τουλάχιστον όσον αφορά τη συμπεριφορά των Συναρτήσεων Αυτοσυσχέτισης όσο και η Μερικής Αυτοσυσχέτισης.

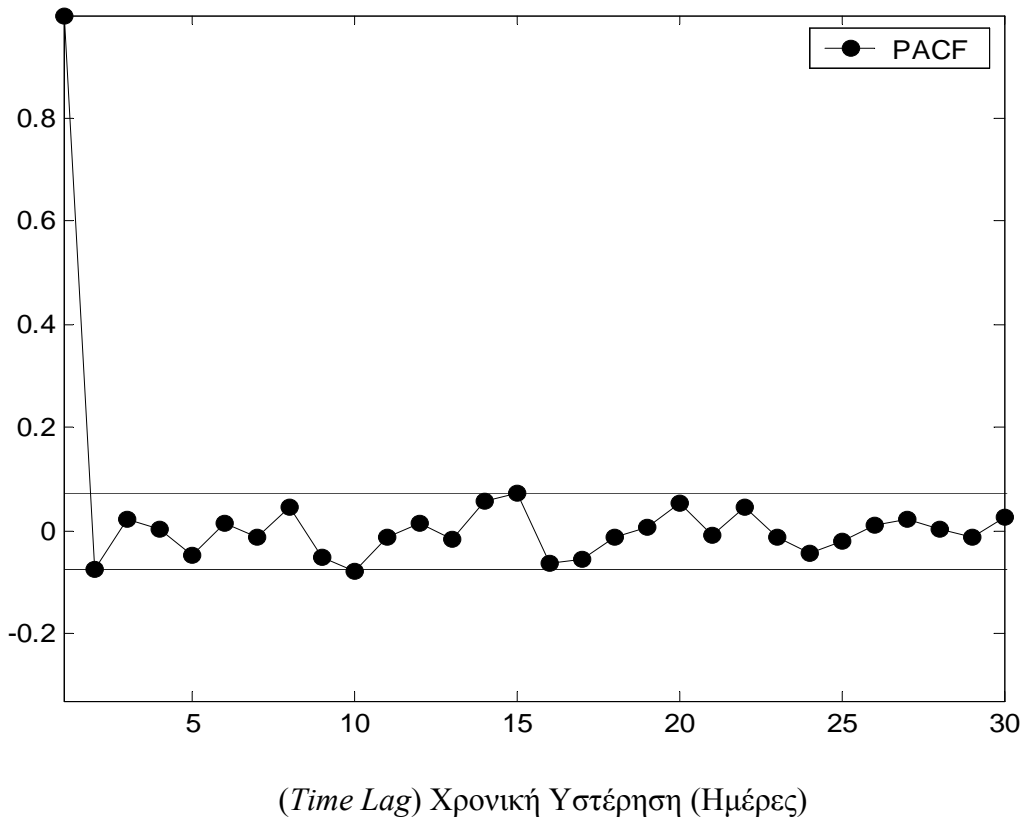
Επειδή όμως δεν μπορούμε να μείνουμε μόνο με τον οπτικό έλεγχο και με σκοπό τα αποτελέσματά μας να είναι όσον το δυνατό πιο σωστά στατιστικά εφαρμόστηκε ένα ακόμα κριτήριο τυχαιότητας (*randomness test*).



Εικ. 4-8. Έξοδος του μοντέλου ARMA (2,6) όπως αυτό περιγράφεται από την εξίσωση (4-2).



Εικ. 4-9. Συνάρτηση Αυτοσυσχέτισης (ACF) για το μοντέλο ARMA(2,6) Οι διακεκομμένες γραμμές αναπαριστούν τα επιτρεπόμενα όρια διακύμανσης ( $\pm 1.96/\sqrt{730}$ ).



**Εικ.4-10.** Συνάρτηση Μερικής Αυτοσυσχέτισης (*PACF*) για το μοντέλο  $ARMA(2,6)$  Οι γραμμές αναπαριστούν τα επιτρεπόμενα όρια διακύμανσης  $(\pm 1.96/\sqrt{730})$ .

Το κριτήριο αυτό, που ονομάζεται *Portmanteau test*, αναλύθηκε και εφαρμόστηκε από τους Ljung & Box το 1978 [116]. Η λειτουργία περιγράφεται ακολούθως:

Μέχρι τώρα εξετάζουμε αν κάθε ένα δείγμα της συνάρτησης αυτοσυσχέτισης,  $r_j$ , εμπίπτει στα όρια που καθορίζονται από το  $\pm 1.96/\sqrt{730}$ . Αυτό μπορεί να αντικατασταθεί από το προαναφερθέν στατιστικό κριτήριο το οποίο περιγράφεται από την εξίσωση 4-3, ( $n$  είναι ο αριθμός των δειγμάτων, εδώ  $n = 730$ ):

$$Q = n(n+2) \sum_{j=1}^h \hat{r}^2(j)/(n-j) \quad (4-3)$$

και η κατανομή του μπορεί να προσεγγιστεί επιτυχώς από τη στατιστική κατανομή  $\chi^2$  με  $h$  βαθμούς ελευθερίας (*degrees of freedom*). Αν η τιμή του  $Q$  είναι υψηλή, αυτό είναι ένδειξη ότι η συνέλιξη μεταξύ των δειγμάτων είναι τόσο μεγάλη



που δεν είναι δυνατό αυτά να προέρχονται από μια ανεξάρτητη και ταυτοτική κατανομή. Ο λόγος για να απορριφθεί η υπόθεση ότι τα δεδομένα μας δεν ανήκουν σε μια ανεξάρτητη και ταυτοτική κατανομή είναι στο επίπεδο του 5% ( $\alpha = 5\% = 0.05$ ) που εξετάζουμε η τιμή  $Q$  να είναι μεγαλύτερη από την τιμή  $\chi^2_{1-\alpha}$ , δηλαδή την τιμή της στατιστικής κατανομής  $\chi^2$  στο διάστημα  $(1-\alpha)$ .

Χρησιμοποιώντας το Matlab® [117] και για  $\alpha = 5\% = 0.05$  βρήκαμε


$$Q = 18.21 \quad p\text{-value} = 0.8149$$

$p$ -value είναι μια ακόμη ένδειξη του *Portmanteau test*. Αν η τιμή της είναι μικρότερη από 0.05 τότε μπορούμε να πούμε ότι τα δεδομένα δεν αντιστοιχούν σε ανεξάρτητη και ταυτοτική κατανομή. Επίσης από στατιστικούς πίνακες βρέθηκε ότι η τιμή της κατανομής  $\chi^2_{1-\alpha}$  για  $\alpha = 5\% = 0.05$ , και 20 βαθμούς ελευθερίας είναι 31.41. Άρα μπορούμε πια με ασφάλεια να πούμε πως το μοντέλο ARMA μπορεί να περιγράψει τα επεξεργασμένα δεδομένα με επιτυχία.

#### 4.3.1. Σύγκριση Κριτηρίων

Στα επεξεργασμένα δεδομένα, όπως αυτά παρουσιάζονται στην Εικόνα 4-3, προστίθεται θόρυβος διασποράς  $\mathbf{R} = 1.2$ , με σκοπό να δημιουργηθεί μια διαφοροποιημένη χρονική σειρά (Εικόνα 4-11). Έπειτα πραγματοποιείται μια σύγκριση ανάμεσα σε μια σειρά από καταξιωμένα κριτήρια σχετικά με την επιτυχή αναγνώριση της τάξης και των συντελεστών του υπάρχοντος μοντέλου ARMA υπό την επίδραση υψηλού θορύβου. Ονομαστικά τα κριτήρια αυτά είναι *Corrected Akaike Criterion (AICC)* (4-1), *Akaike's Information Criterion (AIC)* (3-10), *Bayesian Information Criterion (BIC)* (3-11) και τέλος ο Αλγόριθμος πολυμοντελικού Διαμελισμού (ή φίλτρο Λαϊνιώτη) *MMPF* η περιγραφή του οποίου για τα μοντέλα τύπου ARMA έγινε στο κεφάλαιο 3.


Η σύγκριση των κριτηρίων επαναλήφθηκε 100 φορές (100 *Monte Carlo Runs-MCRs*) για τρία σύνολα διαφορετικών αρχικών δεδομένων (50, 150, 300 δείγματα).




Ημέρες: 1/1/2004 – 31/12/2005

**Εικ. 4-11.** Το σύνολο των επεξεργασμένων δεδομένων (3<sup>ο</sup> παράθυρο) που χρησιμοποιήθηκε για τη σύγκριση των τριών κριτηρίων.

Από αυτή τη σύγκριση κριτηρίων μπορούμε να καταλήξουμε σε μια σειρά συμπερασμάτων. Κατ' αρχήν από την Εικόνα 4-13 μπορούμε να πούμε ότι το φίλτρο Λαϊνιώτη (*MMPF*) είναι ικανό να εκτιμήσει με απόλυτη επιτυχία την τάξη του μοντέλου χρησιμοποιώντας το μικρότερο από τα αρχικά σύνολα δεδομένων, δηλαδή εκείνο με τα 50 δείγματα. Τα κριτήριο *BIC* είναι και αυτό εξίσου αλάνθαστο για το μεγαλύτερο από τα τρία σύνολα δεδομένων. Επίσης το φίλτρο Λαϊνιώτη υπολογίζει με σχετική ακρίβεια και τους συντελεστές του μοντέλου ARMA (Πίνακας 4-1), ενώ πολύ γρήγορα, μέσα σε 21 βήματα αναγνωρίζει επιτυχώς την τάξη του μοντέλου, Εικόνα 4-12.



Εικ.4-12. Ακολουθία των εκ των υστέρων πιθανοτήτων φίλτρου Λαϊνιώτη (MMPF).



Εικ. 4-13. Σύγκριση κριτηρίων

<i>Πραγματικοί Τελεστές</i>	<i>Εκτιμώμενοι Τελε- στές</i>	$\sqrt{\text{Μέσο Λάθος}}$
-0.3153	-0.4636	0.1822
0.0287	0.0246	0.0899
-0.1363	-0.1197	0.1616
0.1985	0.1629	0.0822
0.1604	0.1696	0.1072
0.4057	0.4730	0.1378
0.4211	0.5088	0.1942
0.2417	0.3029	0.0860

**Πίνακας 4-1.** Πραγματικοί και Εκτιμώμενοι Τελεστές και η Τετραγωνική ρίζα του αντίστοιχου Μέσου Τετραγωνικού Λάθους (*Root Mean Square Error*)

#### 4.4 Εκτίμηση της διακύμανσης της ζήτησης του ηλεκτρικού φορτίου.

Η εκτίμηση της διακύμανσης της ζήτησης του ηλεκτρικού φορτίου είναι ένα πολύ σημαντικό ζήτημα και διαδραματίζει εξίσου σπουδαίο ρόλο στον ενεργειακό σχεδιασμό και τη λειτουργία του ηλεκτρικού συστήματος παραγωγής και διανομής της ηλεκτρικής ενέργειας. Βασικές επιχειρησιακές λειτουργίες όπως η αξιοπιστία του συστήματος, η οικονομοτεχνική του μελέτη, η συντήρησή του αλλά ακόμα και ο υπολογισμός του απαραίτητου φορτίου καυσίμων που απαιτείται για στην παραγωγή της ηλεκτρικής ενέργειας σε μια χώρα μπορούν να σχεδιαστούν αποτελεσματικότερα αν υπάρχει μια μέθοδος ακριβούς και αξιόπιστης εκτίμησης της διακύμανσης της ζήτησης του ηλεκτρικού φορτίου. Η εκτίμηση του ηλεκτρικού φορτίου μπορεί να αφορά τη διακύμανσή του τους αμέσως επόμενους μήνες, (*mid range forecast*), ή την επόμενη εβδομάδα ή μέρα (*short range forecast*) ή ακόμα και για τις αμέσως επόμενες ώρες ή λεπτά (*ultra short range forecast*).

#### 4.4.1 Μηνιαία Εκτίμηση της Διακύμανσης Φορτίου - Σύγκριση Κριτηρίων

Σε αυτήν την ενότητα τα επεξεργασμένα δεδομένα, Εικόνες 4-3 – 4-6, τα οποία καλύπτουν τη χρονική περίοδο μεταξύ 1<sup>ης</sup> Ιανουαρίου 2004 – 31<sup>ης</sup> Δεκεμβρίου 2005 χρησιμοποιούνται από τέσσερις διαφορετικές μεθόδους εκτίμησης, ονομαστικά:

*Corrected Akaike Criterion (AICC)*, (4-1)

*Akaike's Information Criterion (AIC)*, (3-10)

*Bayesian Information Criterion (BIC)*, (3-11), και τέλος

*Αλγόριθμος Πολύ-μοντελικού Διαμελισμού* (ή φίλτρο Λαϊνιώτη) *MMPF*,

με στόχο την εκτίμηση της διακύμανσης της ζήτησης του ηλεκτρικού φορτίου για την περίοδο από 1<sup>η</sup> Ιανουαρίου 2006 έως την 31<sup>η</sup> Δεκεμβρίου 2006. Η διακύμανση του φορτίου για τη χρονιά 2006 μας είναι γνωστή, έτσι λοιπόν είναι δυνατόν να δούμε ποια μέθοδος προσεγγίζει καλύτερα τα δεδομένα αλλά και να υπολογιστεί το σφάλμα της κάθε μεθόδου.

Για κάθε μια μέρα της χρονιάς 2006 υιοθετήθηκε η μέθοδος της προσαρμοζόμενης εκτίμησης της επόμενης μέρας (*adaptive day ahead prediction*). Αυτό σημαίνει πως η εκτίμηση της διακύμανσης του φορτίου γίνεται μέρα-μέρα χρησιμοποιώντας το καλύτερο μοντέλο ARMA(2,6) αντί να χρησιμοποιείται ένα μόνο σταθερό μοντέλο όπως για παράδειγμα αυτό που περιγράφεται από την εξίσωση 4-2. Συγκεκριμένα για την εκτίμηση της διακύμανσης της ζήτησης του ηλεκτρικού φορτίου στις 2 Φεβρουαρίου 2006, χρησιμοποιήθηκαν οι προηγούμενες 730 μετρήσεις και σε αυτές προσαρμόστηκε το καλύτερο μοντέλο ARMA(2,6) το οποίο εκτιμά η κάθε μέθοδος για τα συγκεκριμένα δεδομένα.

Η σύγκριση των προαναφερθέντων κριτηρίων κάλυψε τις ακόλουθες περιόδους:

1<sup>η</sup> Ιανουαρίου – 1<sup>η</sup> Μαρτίου,

1<sup>η</sup> Απριλίου– 31<sup>η</sup> Μαΐου,

1<sup>η</sup> Αυγούστου -30<sup>η</sup> Σεπτεμβρίου του έτους 2006.

Από την οπτική απεικόνιση των αποτελεσμάτων της σύγκρισης όπως αυτά παρουσιάζονται στις εικόνες 4-14 – 4-16 όλες οι μέθοδοι φαίνεται να έχουν ικανοποιητική και σχεδόν παρόμοια απόδοση όσον αφορά την εκτίμηση της διακύμανσης της ζήτησης του φορτίου. Για να υπάρχει όμως ένα κοινό μέτρο σύγκρισης χρησιμοποιήθηκε το στατιστικό κριτήριο του μέσου εκατοστιαίου λάθους της απόλυτης τιμής (*Mean Absolute Percentage Error*) *MAPE*. Το κριτήριο ορίζεται ως:

$$MAPE = \frac{1}{k} \sum_{i=1}^k \left| \hat{x}_i - x_i \right| \times 100\% \quad (4-4)$$

Βάση του παραπάνω κριτηρίου η επίδοση της κάθε μεθόδου αποτυπώνεται στον πίνακα 4-2.

<i>MAPE</i>	<i>Κριτήριο</i>
1.87%	<i>MMPF</i>
2.35%	AIC
1.98%	AICC
2.11%	BIC

**Πίνακας 4-2.** Πίνακας του MAPE για κάθε κριτήριο για όλο το έτος 2006. Το καλύτερο αποτέλεσμα δίνει το φίλτρο Λαϊνιώτη *MMPF*

Βάση του παραπάνω πίνακα είναι εμφανές πως το φίλτρο Λαϊνιώτη *MMPF*, δίνει την καλύτερη εκτίμηση αφού παρουσιάζει το μικρότερο λάθος. Το γενικότερο όμως συμπέρασμα είναι πως όλες οι μέθοδοι ανταποκρίνονται εξίσου ικανοποιητικά, αφού το ποσοστό λάθους μπορεί να θεωρηθεί σχετικά μικρό.

#### 4.4.2 Εβδομαδιαία Εκτίμηση της Διακύμανσης Φορτίου - Σύγκριση Κριτηρίων

Από τον πίνακα 4-2 είναι εμφανές ότι το φίλτρο Λαϊνιώτη έχει το μικρότερο λάθος συγκριτικά με τις υπόλοιπες μεθόδους. Τα σύγχρονα δεδομένα απαιτούν λάθος στην πρόγνωση όχι μεγαλύτερο του 2.5% [118]. Αυτό σημαίνει ότι για ένα χρόνο ή για 2 μήνες μπορεί το μέσο λάθος να είναι μικρότερο του 2.5%, όμως αν

ελέγξουμε την πρόγνωση του φορτίου της επόμενης μέρας ή εβδομάδας το λάθος αυτό μπορεί να είναι μεγαλύτερο.

Ο στόχος της ενότητας αυτής είναι να ερευνηθεί αν κάποια από τις μεθόδους που χρησιμοποιήθηκαν πριν μπορούν να εκτιμήσουν τη διακύμανση του ηλεκτρικού φορτίου για μια εβδομάδα, χωρίς να υπερβούν το όριο λάθους 2.5%. Στα συγκρινόμενα κριτήρια αυτή τη φορά προστίθενται και τα Τεχνητά Νευρωνικά Δίκτυα (*Artificial Neural Networks-ANN*). Το συγκεκριμένο νευρωνικό δίκτυο που χρησιμοποιήθηκε περιείχε ένα κρυμμένο στρώμα αποτελούμενο από δεκαεπτά κρυφούς νευρώνες, πέντε νευρώνες εισόδου και έναν νευρώνα εξόδου. Στο παράρτημα Α το νευρωνικό αυτό δίκτυο περιγράφεται αναλυτικά. Επιπλέον πραγματοποιείται η εκτίμηση της ημερήσιας μέγιστης ζήτησης φορτίου (*daily peak forecast*).

Η διαδικασία περιγράφεται ακολούθως: Καταγράφεται μια περίοδος δυο μηνών, ανά εποχή του έτους, και στη συνέχεια χρησιμοποιούνται και οι 5 προαναφερθείσες μέθοδοι με στόχο την εκτίμηση της διακύμανσης του φορτίου για την αμέσως επόμενη εβδομάδα. Τα αποτελέσματα παρουσιάζονται στους πίνακες 4-3 έως 4-7. Το εκτιμώμενο λάθος στους πίνακες 4-4 έως 4-7 ορίζεται ως 
$$\left( \frac{| \text{Πραγματική Τιμή} - \text{Εκτιμώμενη Τιμή} |}{\text{Πραγματική Τιμή}} 100\% \right).$$

Από τους πίνακες 4-3 έως 4-7 μπορούμε να συμπεράνουμε ότι όλα τα κριτήρια αποδίδουν ικανοποιητικά κρίνοντας από το μέσο εκτιμώμενο λάθος το οποίο δεν υπερβαίνει το όριο του 2.5%. Από τους ίδιους πίνακες είναι εμφανές πως όλες οι μέθοδοι παρουσιάζουν μεγαλύτερο λάθος κατά τη διάρκεια του Σαββατοκύριακου. Αυτό συμβαίνει κυρίως διότι τα συγκεκριμένα δεδομένα παρουσιάζουν συμπεριφορά *non-Gaussian*, γεγονός που δε λήφθηκε υπ' όψιν κατά την αρχική επεξεργασία και παραγωγή του μοντέλου ARMA με τη μέθοδο AICC. Το πρόβλημα αυτό θα μελετηθεί στην επόμενη ενότητα με τη χρησιμοποίηση μοντέλων SARIMA.

Σενάριο	Περίοδος Καταγραφής	Περίοδος Εκτίμησης
1	5/1/2004 – 5/3/2004	8/3/2004 – 14/3/2004 Δευτέρα – Κυριακή (Άνοιξη)
2	5/4/2004 – 5/6/2004	7/6/2004 – 13/6/2004 Δευτέρα – Κυριακή (Καλοκαίρι)
3	26/7/2004 – 10/9/2004	13/9/2004 – 19/09/2003 Δευτέρα – Κυριακή (Φθινόπωρο)
4	25/10/2004 – 3/12/2004	6/12/2004 – 12/12/2004 Δευτέρα – Κυριακή (Χειμώνας)

Πίνακας 4-3. Περίοδοι καταγραφής και εκτίμησης του ηλεκτρικού φορτίου.

Ημέρα Μέγιστο φορτίο (MW)	Κριτήριο Εκτιμώμενο Μέγιστο Φορτίο (MW) (Εκτιμώμενο Λάθος (%))				
	MMPF	AICC	AIC	BIC	ANN
Δευτέρα 8 7345	7257 (1.21)	7244 (1.37)	7176 (2.3)	7208 (1.87)	7203 (1.93)
Τρίτη 9 7254	7158 (1.32)	7224 (0.42)	7225 (0.39)	7235 (0.26)	7212 (0.58)
Τετάρτη 10 7123	7103 (0.27)	7077 (0.65)	7016 (1.5)	7021 (1.43)	7029 (1.32)
Πέμπτη 11 7018	6996 (0.31)	6991 (0.38)	6982 (0.51)	6983 (0.49)	6958 (0.86)
Παρασκευή 12 7869	7837 (0.41)	7686 (2.33)	7685 (2.34)	7713 (1.98)	7816 (0.67)
Σάββατο 13 6672	6325 (5.2)	6425 (3.7)	6384 (4.32)	6404 (4.01)	6415 (3.85)
Κυριακή 14 6125	5970 (4.5)	5938 (5.01)	5926 (5.2)	5937 (5.03)	5995 (4.1)
<b>Μέσο Εκτι- μώμενο Λάθος (%)</b>	<b>1.89</b>	<b>1.98</b>	<b>2.36</b>	<b>2.15</b>	<b>1.90</b>

Πίνακας 4-4. Σενάριο 1: 8 Μαρτίου – 14 Μαρτίου

Επίσης από τους πίνακες 4-3 έως 4-7 μπορούμε να συμπεράνουμε ότι όλα τα κριτήρια αποδίδουν ικανοποιητικά κρίνοντας από το μέσο εκτιμώμενο λάθος το οποίο δεν υπερβαίνει το όριο του 2.5%.



Ημέρα Μέγιστο φορτίο (MW)	Κριτήριο Εκτιμώμενο Μέγιστο Φορτίο (MW) (Εκτιμώμενο Λάθος (%))				
	MMPF	AICC	AIC	BIC	ANN
Δευτέρα 7 8456	8421 (0.41)	8420 (0.43)	8253 (2.4)	8316 (1.65)	7203 (1.93)
Τρίτη 8 8219	8193 (0.32)	8162 (0.69)	8175 (0.53)	8175 (0.53)	7212 (0.58)
Τετάρτη 9 8861	8744 (1.32)	8720 (1.59)	8686 (1.98)	8675 (2.1)	7029 (1.32)
Πέμπτη 10 8533	8490 (0.531)	8472 (0.72)	8472 (0.72)	8493 (0.47)	6958 (0.86)
Παρασκευή 11 8653	8549 (1.2)	8506 (1.7)	8549 (1.2)	8569 (0.97)	7419 (0.67)
Σάββατο 12 8126	7728 (4.9)	7718 (5)	7711 (5.1)	7718 (5.02)	6415 (3.85)
Κυριακή 13 8087	7707 (4.7)	7715 (4.6)	7690 (4.9)	7696 (4.83)	5995 (4.1)
<b>Μέσο Εκτιμώ- μενο Λάθος (%)</b>	<b>1.91</b>	<b>2.10</b>	<b>2.40</b>	<b>2.22</b>	<b>1.90</b>

Πίνακας 4-5. Σενάριο 2: 7 Ιουνίου – 13 Ιουνίου.

Ημέρα Μέγιστο φορτίο (MW)	Κριτήριο Εκτιμώμενο Μέγιστο Φορτίο (MW) (Εκτιμώμενο Λάθος (%))				
	MMPF	AICC	AIC	BIC	ANN
Δευτέρα 13 9845	9727 (1.2)	9775 (0.71)	9716 (1.31)	9781 (0.65)	9661 (1.87)
Τρίτη 14 9743	9708 (0.36)	9705 (0.39)	9705 (0.39)	9572 (1.75)	9683 (0.62)
Τετάρτη 15 9821	9688 (1.35)	9683 (1.41)	9607 (2.18)	9744 (0.78)	9697 (1.26)
Πέμπτη 16 9654	9616 (0.39)	9565 (0.92)	9565 (0.92)	9607 (0.49)	9584 (0.73)
Παρασκευή 17 9549	9476 (0.76)	9348 (2.1)	9354 (2.04)	9455 (0.98)	9493 (0.59)
Σάββατο 18 9323	8905 (4.48)	8903 (4.5)	8903 (4.5)	8838 (5.2)	8949 (4.01)
Κυριακή 19 9256	8828 (4.62)	8895 (3.9)	8775 (5.2)	8801 (4.92)	8839 (4.5)
<b>Μέσο Εκτιμώμε- νο Λάθος (%)</b>	<b>1.90</b>	<b>1.99</b>	<b>2.36</b>	<b>2.11</b>	<b>1.94</b>

Πίνακας 4-6. Σενάριο 3: 13 Σεπτεμβρίου – 19 Σεπτεμβρίου

Ημέρα Μέγιστο φορτίο (MW)	Κριτήριο Εκτιμώμενο Μέγιστο Φορτίο (MW) (Εκτιμώμενο Λάθος (%))				
	MMPF	AICC	AIC	BIC	ANN
Δευτέρα 6 9421	9374 (1.2)	9323 (1.04)	9318 (1.31)	9223 (2.1)	9234 (1.98)
Τρίτη 7 9512	9410 (0.36)	9410 (1.07)	9427 (0.39)	9438 (0.78)	9462 (0.53)
Τετάρτη 8 9318	9269 (1.35)	9219 (1.06)	9090 (2.18)	9220 (1.05)	9229 (0.95)
Πέμπτη 9 9224	9162 (0.39)	9149 (0.81)	9154 (0.92)	9154 (0.76)	9154 (0.76)
Παρασκευή 10 9471	9342 (0.76)	9315 (1.65)	9315 (2.04)	9444 (0.28)	9355 (1.23)
Σάββατο 11 9176	8781 (4.48)	8781 (4.3)	8726 (4.5)	8711 (5.07)	8881 (3.21)
Κυριακή 12 9021	8588 (4.62)	8660 (4.0)	8588 (5.2)	8593 (4.74)	8593 (4.74)
<b>Μέσο Εκτιμώμε- νο Λάθος (%)</b>	<b>1.89</b>	<b>1.99</b>	<b>2.36</b>	<b>2.11</b>	<b>1.90</b>

Πίνακας 4-7. Σενάριο 4: 6 Δεκεμβρίου – 12 Δεκεμβρίου

Από τους ίδιους πίνακες είναι εμφανές πως όλες οι μέθοδοι παρουσιάζουν μεγαλύτερο λάθος κατά τη διάρκεια του Σαββατοκύριακου. Αυτό συμβαίνει κυρίως διότι τα συγκεκριμένα δεδομένα παρουσιάζουν συμπεριφορά *non-Gaussian*, γεγονός που δε λήφθηκε υπ' όψιν κατά την αρχική επεξεργασία και παραγωγή του μοντέλου ARMA με τη μέθοδο AICC. Το πρόβλημα αυτό θα μελετηθεί στην επόμενη ενότητα με τη χρησιμοποίηση μοντέλων SARIMA.

#### 4.4.3 Εκτίμηση της Διακύμανσης Φορτίου χρησιμοποιώντας μοντέλα SARIMA.

Το θεωρητικό κομμάτι για τα μοντέλα τύπου SARIMA καθώς και ο αλγόριθμος υλοποίησής τους έχουν ήδη παρουσιαστεί στο κεφάλαιο 2. Το μοντέλο SARIMA στο οποίο καταλήξαμε είναι της μορφής ARIMA (1,1,1)x(0,1,1)<sub>36</sub>, (όπου (1,1,1)x(0,1,1) = (p,d,q)x(P,D,Q)). Όπως φαίνεται και από τις εικόνες 4-17 – 4-20 το μοντέλο λειτουργεί επιτυχώς με μικρό εκτιμώμενο λάθος τόσο στη ζήτηση του

φορτίου κατά τη διάρκεια εργασιμων ημερών (Δευτέρα - Παρασκευή), όσο και στη διακύμανση του φορτίου τη διάρκεια του Σαββατοκύριακου, υπό την προϋπόθεση πως τα παρελθόντα δεδομένα ανήκουν στην ίδια κατηγορία με αυτά που θα προβλεφθούν.

Εκτός από τη συνηθισμένη εβδομαδιαία διακύμανση του φορτίου υπάρχουν και μια σειρά από άλλες καταστάσεις όπως διακοπές ρεύματος (*blackout*) ή ξαφνική αύξηση της ζήτησης του φορτίου (*peak*). Αυτά τα συμβάντα δεν είναι περιοδικά αλλά εμφανίζονται σε τυχαίες χρονικές στιγμές, συνεπώς το περιοδικό μοντέλο δεν εξυπηρετεί ιδιαίτερα. Εδώ μοντελοποιούνται δυο τέτοια συμβάντα, μια ξαφνική αύξηση της ζήτησης του φορτίου (*peak*) και μια διακοπή ρεύματος (*blackout*), εικόνα 4-21, χρησιμοποιώντας δυναμικά μοντέλα (*state space models*) ως εξής:


$$z_k = x_k + v_k, \quad \text{and,} \quad a) x_{k+1} = 1.8 \cdot x_k, \quad b) x_{k+1} = x_k \quad (= 0)$$

Να σημειωθεί ότι ο οριζόντιος άξονας στις εικόνες 4-17 – 4-27 που αναπαριστά το χρόνο είναι σε ώρες.


Τα τέσσερα υποψήφια μοντέλα που περιγράφηκαν παραπάνω (ζήτηση φορτίου Δευτέρα – Παρασκευή, ζήτηση φορτίου Σαββατοκύριακου, ξαφνική αύξηση της ζήτησης, και διακοπή ρεύματος) θα χρησιμοποιηθούν σε συνδυασμό με το φίλτρο Λαϊνιώτη (*MMPF*) με στόχο τον εντοπισμό της διακύμανσης του φορτίου. Ένα δείγμα δεκαπέντε ημερών της κάθε μιας ακολουθίας διακύμανσης του φορτίου απεικονίζεται στην Εικόνα 4-22.

Όπως και στο 2<sup>ο</sup> κεφάλαιο, το φίλτρο Λαϊνιώτη χρησιμοποιεί 4 στοιχειώδη φίλτρα Kalman, κάθε ένα από τα οποία αντιστοιχεί σε μια από τις 4 διακυμάνσεις της ζήτησης του φορτίου, όπως φαίνεται στην Εικόνα 4-22. Η εκ των υστέρων πιθανότητα  $p(n / k)$  του κάθε μοντέλου χρησιμοποιείται για να ταυτοποιηθεί ο τύπος της κίνησης του φορτίου. Το μοντέλο στο οποίο αντιστοιχεί η μεγαλύτερη εκ των υστέρων πιθανότητα επιλέγεται από τον αλγόριθμο ως το σωστό.

#### 4.4.4 Αποτελέσματα




Εικ.4-14. Σύγκριση κριτηρίων. 1<sup>η</sup> Ιανουαρίου - 1<sup>η</sup> Μαρτίου




Εικ.4-15. Σύγκριση κριτηρίων. 1<sup>η</sup> Απριλίου - 31<sup>η</sup> Μαΐου


Εικ. 4-16. Σύγκριση κριτηρίων. 1<sup>η</sup> Αυγούστου - 30<sup>η</sup> Σεπτεμβρίου




Εικ. 4-17. Ημερήσια εκτίμηση της διακύμανσης του ηλεκτρικού φορτίου Δευτέρα - Παρασκευή, χρησιμοποιώντας το μοντέλο  $ARIMA(1,1,1) \times (0,1,1)_{36}$ . Η εκτίμηση ξεκινά στο βήμα 145. Τα προηγούμενα βήματα αντικαταστάθηκαν από το μέσο όρο όλων των προηγούμενων εργασιμων ημερών.



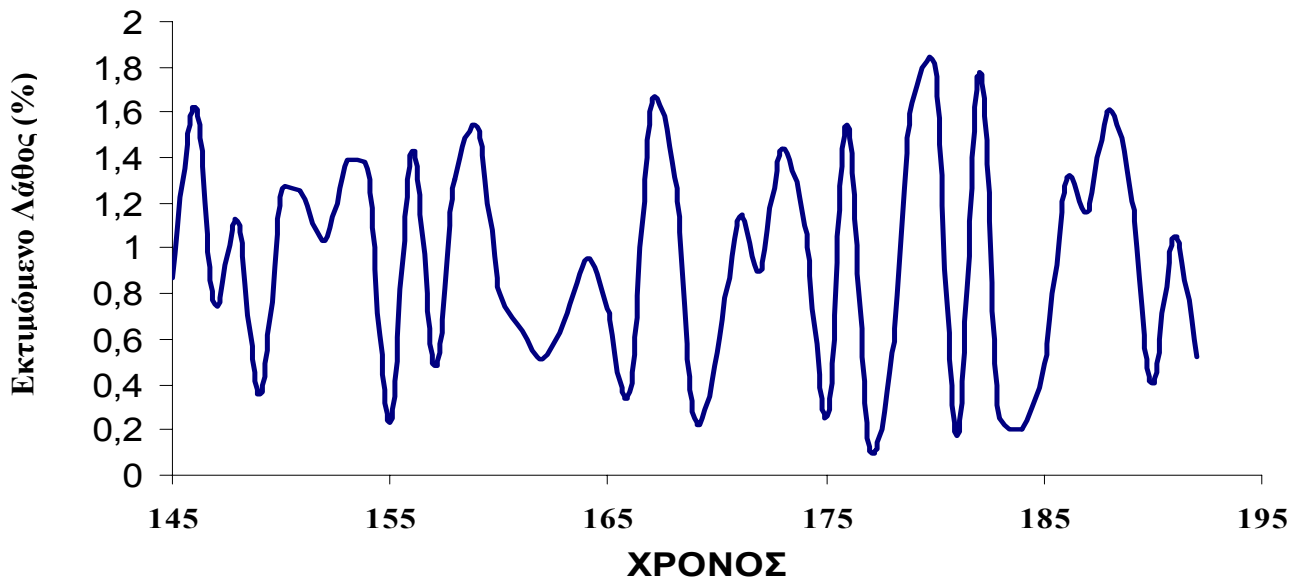
**Εικ. 4-18.** Ημερήσια εκτίμηση της κίνησης του δικτύου σε ημέρα Σαββατοκύριακου, χρησιμοποιώντας το μοντέλο ARIMA (1,1,1)×(0,1,1)<sub>36</sub>. Η εκτίμηση ξεκινά στο βήμα 145. Τα προηγούμενα βήματα αντικαταστάθηκαν από το μέσο όρο όλων των προηγούμενων Σαββατοκύριακων ή αργιών.




**Εικ 4-19.** Εκτιμώμενο Λάθος  $\left( \frac{|Πραγματική\ Τιμή - Εκτιμώμενη\ Τιμή|}{Πραγματική\ Τιμή} \cdot 100\% \right)$ . Δευτέρα - Παρασκευή




Εικ. 4-20. Εκτιμώμενο Λάθος  $\left( \frac{|Πραγματική\ Τιμή - Εκτιμώμενη\ Τιμή|}{Πραγματική\ Τιμή} 100\% \right)$ . Σαββατοκύριακο.




Εικ. 4-21. Σύνολο Δεδομένων για μια εβδομάδα. Εμπεριέχει ξαφνικές αυξήσεις στη ζήτηση του φορτίου (*peaks*) και διακοπές ρεύματος (*blackout*).



Εικ. 4-22. Δείγμα διακόμανσης της ζήτησης του φορτίου με διαφορετικές συνθήκες




Εικ. 4-23. Το φίλτρο Λαϊνιώτη εντοπίζει με επιτυχία τις αλλαγές στη διακόμανση του ηλεκτρικού φορτίου.







Εικ. 4-24. Εκτίμηση της διακύμανσης της ζήτησης του φορτίου από το φίλτρο Λαϊνιώτη




Εικ. 4-25. Εκτιμώμενο Λάθος  $\left( \frac{| \text{Πραγματική Τιμή} - \text{Εκτιμώμενη Τιμή} |}{\text{Πραγματική Τιμή}} 100\% \right)$  φίλτρου Λαϊνιώτη.



Εικ. 4-26. Εκτίμηση της διακύμανσης της ζήτησης του φορτίου από το μοντέλο SARIMA.



Εικ. 4-27. Εκτιμώμενο Λάθος  $\left( \frac{| \text{Πραγματική Τιμή} - \text{Εκτιμώμενη Τιμή} |}{\text{Πραγματική Τιμή}} 100\% \right)$  SARIMA



## 4.5. Συμπεράσματα

Στο πρώτο μέρος του κεφαλαίου αυτού πραγματοποιήθηκε η μοντελοποίηση της ζήτησης της διακύμανσης του ηλεκτρικού φορτίου μέσω ενός μοντέλου ARMA, χρησιμοποιώντας τη μέθοδο των Nowicka-Zagrajek και Weron [106, 107], καθώς και το εργαλείο του MATLAB® *Modeling and Forecasting Electricity Loads and Prices (MFE)* το οποίο είναι ελεύθερο για δημόσια χρήση [115]. Από τον οπτικό έλεγχο των αποτελεσμάτων, το μοντέλο το οποίο προέκυψε φαίνεται να περιγράφει με επιτυχία τα δεδομένα αφού δεν παρουσιάζει ίχνη μη μηδενικής μέσης τιμής ή μη σταθερής απόκλισης (*non-constant variance*). Επίσης τόσο η Συνάρτηση Αυτοσυσχέτισης (*Auto Correlation Function - ACF*) όσο και η Μερική Συνάρτηση Αυτοσυσχέτισης (*Partial Auto Correlation Function - PACF*) τείνουν πολύ γρήγορα στο μηδέν μέσα στα επιτρεπτά όρια, γεγονός που υποδηλώνει ότι δεν υπάρχει συσχέτιση (*correlation*) μεταξύ των δεδομένων.

Τέλος με τη χρησιμοποίηση του στατιστικού κριτηρίου *Portmanteau test*, αποδείχθηκε ότι η συμπεριφορά του εν λόγω μοντέλου αντιστοιχεί σε μια *ανεξάρτητη και ταυτοτική κατανομή*. Μέσω των παραπάνω μπορεί κάποιος να οδηγηθεί με ασφάλεια στο συμπέρασμα πως το μοντέλο ARMA μπορεί να περιγράψει τα επεξεργασμένα δεδομένα με επιτυχία

Στη συνέχεια στα επεξεργασμένα δεδομένα προστίθεται υψηλός θόρυβος με σκοπό τη δημιουργία μιας διαφοροποιημένης χρονικής σειράς. Με τα νέα αυτά δεδομένα πραγματοποιείται μια σύγκριση μεταξύ τριών κριτηρίων αναγνώρισης της τάξης και των συντελεστών μοντέλων ARMA, ονομαστικά *Corrected Akaike Criterion (AICC)*, *Akaike's Information Criterion (AIC)*, *Bayesian Information Criterion (BIC)* και του Αλγόριθμου πολυ-μοντελικού Διαμελισμού (ή φίλτρο Λαϊνιώτη) MMPF.

Η σύγκριση έδειξε ότι το φίλτρο Λαϊνιώτη (*MMPF*) είναι ικανό να εκτιμήσει με απόλυτη επιτυχία την τάξη του μοντέλου χρησιμοποιώντας το μικρότερο από τα αρχικά σύνολα δεδομένων, 50 μόλις δείγματα. Το κριτήριο *BIC* είναι και αυτό

εξίσου αλάνθαστο για το μεγαλύτερο από τα τρία σύνολα δεδομένων. Επίσης το φίλτρο Λαϊνιώτη υπολογίζει με σχετική ακρίβεια και τους συντελεστές του μοντέλου ARMA, ενώ πολύ γρήγορα, μέσα σε 21 βήματα αναγνωρίζει επιτυχώς τη συνολική  $(p+q)$  τάξη του μοντέλου.

Στο επόμενο στάδιο έγινε η εκτίμηση της διακύμανσης της ζήτησης του φορτίου χρησιμοποιώντας και τα τέσσερα προαναφερθέντα κριτήρια. Από τα αποτελέσματα έγινε εμφανές πως όλα είχαν ικανοποιητική απόδοση, όμως το φίλτρο Λαϊνιώτη (*MMPF*) ήταν καλύτερο αφού είχε το μικρότερο μέσο εκατοστιαίο λάθος της απόλυτης τιμής *MAPE*, 1.87%.

Ακολούθως μελετήθηκε η εβδομαδιαία εκτίμηση της διακύμανσης του φορτίου καθώς και η ημερήσια εκτίμηση της μέγιστης ζήτησης. Η απόδοση όλων των μεθόδων μπορεί να χαρακτηριστεί ικανοποιητική. Πιο συγκεκριμένα από τους πίνακες 4-4 έως 4-7 συμπεραίνουμε πως το φίλτρο Λαϊνιώτη μαζί με το Νευρωνικό Δίκτυο παρουσιάζει το μικρότερο μέσο εκτιμώμενο λάθος. Με μια προσεκτικότερη ματιά στους ίδιους πίνακες μπορούμε να συμπεράνουμε πως όλες οι μέθοδοι παρουσιάζουν το μεγαλύτερο λάθος για την εκτίμηση του φορτίου το Σαββατοκύριακο. Αυτό συμβαίνει διότι η συμπεριφορά του φορτίου κατά τη διάρκεια του Σαββατοκύριακου δεν είναι *Gaussian*, κάτι που δεν λήφθηκε υπ' όψιν στο πρώτο στάδιο της επεξεργασίας των δεδομένων όπου είχε ως στόχο την εύρεση ενός μοντέλου ARMA. Για τέτοιου είδους δεδομένα το Νευρωνικό δίκτυο υπερέχει αφού στις 14/3, 12/6, 13/6, 18/9 και 11/12 έχει το μικρότερο λάθος. Επίσης εξίσου καλή απόδοση παρουσιάζει και η μέθοδος AICC για τις 13/3, 19/9 και 12/12.

Για να ξεπεραστεί το προηγούμενο πρόβλημα δοκιμάστηκε η μοντελοποίηση της διακύμανσης του ηλεκτρικού φορτίου μέσω μοντέλου τύπου *SARIMA* όπως και στο 2<sup>ο</sup> κεφάλαιο. Από τις εικόνες 4-23 – 4-24 συμπεραίνουμε ότι το φίλτρο Λαϊνιώτη επεξεργάστηκε επιτυχώς τα πραγματικά δεδομένα και όπως έδειξαν τα αποτελέσματα εντόπισε επιτυχώς τις αλλαγές, που περιέχονταν στο σύνολο των δεδομένων. Επίσης από την εικόνα 4-25 βλέπουμε ότι το λάθος στην εκτίμηση του φίλτρου δεν ξεπερνά το 2.5% γεγονός που σημαίνει ότι η απόδοσή του είναι

εντός των σύγχρονων απαιτήσεων. Επιπλέον το φίλτρο ανταποκρίνεται πολύ γρήγορα στις αλλαγές αυτές γεγονός που υποδηλώνει πως θα μπορούσε να αποδώσει το ίδιο καλά σε πραγματικό χρόνο ακόμα και για διαστήματα δειγματοληψίας μικρότερα της 1 ώρας. Τελειώνοντας θα πρέπει να επισημανθεί ότι στις εικόνες 4-46 και 4-47 απεικονίζεται η συμπεριφορά του μοντέλου *SARIMA*. Είναι εμφανές πως το μοντέλο λειτουργεί πολύ καλά για τις συνήθεις συνθήκες ζήτησης του ηλεκτρικού φορτίου όμως δεν είναι σε θέση να εντοπίσει τις ξαφνικές αλλαγές που ενδεχομένως προκύπτουν αφού αυτές δεν είναι περιοδικές και δεν περιέχονταν στα αρχικά δεδομένα βάσει των οποίων διαμορφώθηκε το μοντέλο.

## Κεφάλαιο 5

Μοντελοποίηση της μεταβολής της αντίστασης του εδάφους χρησιμοποιώντας μοντέλα μεικτών διεργασιών - ARMA: Σύγκριση κριτηρίων


## 5.1. Εισαγωγή

**Η** μεταβολή της αντίστασης του εδάφους αποτελεί σημαντικό στοιχείο που πρέπει να λαμβάνεται υπόψη στη σχεδίαση ηλεκτρολογικών εγκαταστάσεων. Το έδαφος, υπό τις κατάλληλες συνθήκες, αποτελεί ένα ασφαλές σημείο αναφοράς στο οποίο το ηλεκτρικό δυναμικό θεωρείται μηδέν. Αν η τιμή της αντίστασης εδάφους είναι σχετικά χαμηλή, τότε όλο το σύστημα γείωσης μπορεί να θεωρηθεί ότι έχει τάση ίση ή πολύ κοντά στο μηδέν. Όταν όμως η τιμή της αντίστασης εδάφους είναι μεγάλη, τότε οτιδήποτε είναι συνδεδεμένο στο σύστημα γείωσης υπάρχει πιθανότητα να εκτεθεί σε υψηλά και επικίνδυνα ηλεκτρικά δυναμικά, εάν, για παράδειγμα, συμβεί κάποιο σφάλμα (*fault*) ή κάποιο άλλο ατύχημα. Στη βιβλιογραφία υπάρχουν αρκετές τεχνικές για την ανάλυση της δομής του εδάφους και τον υπολογισμό των παραμέτρων της ειδικής αντίστασης του εδάφους άρα και κατ' επέκταση της αντίστασης του εδάφους [119 – 122, 124].

Η κεραυνική συμπεριφορά των γραμμών μεταφοράς υψηλής τάσης είναι στενά συνδεδεμένη με την άρτια και απρόσκοπτη λειτουργία του συνόλου του δικτύου μεταφοράς της ηλεκτρικής ενέργειας. Για παράδειγμα κεραυνοί που έχουν πλήξει ηλεκτρικές γραμμές μεταφοράς υψηλής τάσης έχουν προκαλέσει πολύ σημαντικές ζημιές τόσο σε ηλεκτρολογικό εξοπλισμό όσο και στο ίδιο το σύστημα μεταφοράς της ηλεκτρικής ενέργειας.


Ένας παράγοντας που επηρεάζει σημαντικά την κεραυνική συμπεριφορά των γραμμών μεταφοράς υψηλής τάσης είναι η μορφολογία του εδάφους [123]. Ειδικά σε περιπτώσεις γραμμών μεταφοράς που διέρχονται από περιοχές με διαφορετική σύσταση του εδάφους, η ύπαρξη ακόμα και ενός μικρού αριθμού πύργων σε έδαφος με υψηλές τιμές αντίστασης μπορεί να αλλοιώσει τη γενική κεραυνική συμπεριφορά της γραμμής και να δημιουργήσει μια εντελώς λανθασμένη εντύπωση για ολόκληρη τη γραμμή. Συγκεκριμένα για γραμμές που διέρχονται από πεδιάδες, ακτογραμμές και/ή ορεινές περιοχές η τιμή της αντίστασης του εδάφους

είναι εντελώς διαφορετική όχι μόνο από περιοχή σε περιοχή, αλλά παρουσιάζει διαφορετικές τιμές για την ίδια περιοχή κατά τη διάρκεια του έτους, (Εικ 5-1 – 5-3) [112]. Δεν είναι τυχαίο το γεγονός ότι οι υψηλότερες τιμές για την αντίσταση του εδάφους εμφανίζονται το καλοκαίρι, ειδικότερο το μήνα Ιούλιο ( $7^{ος}$ ) και ανάμεσα σε αυτές τις τιμές οι μέγιστες είναι σε περιοχές ορεινές. Σε κάθε μια από τις εικόνες 5-1–5-3 η περιοχή 1 είναι πεδινή γι' αυτό εμφανίζει μικρότερη τιμή αντίστασης του εδάφους. Η περιοχή 2 είναι ορεινότερη, συνεπώς η τιμή αντίστασης του εδάφους αυξάνεται. Η περιοχή 3 είναι καθαρά ορεινή και εμφανώς παρουσιάζει μεγαλύτερη τιμή αντίστασης του εδάφους συγκριτικά με τις δυο προηγούμενες.

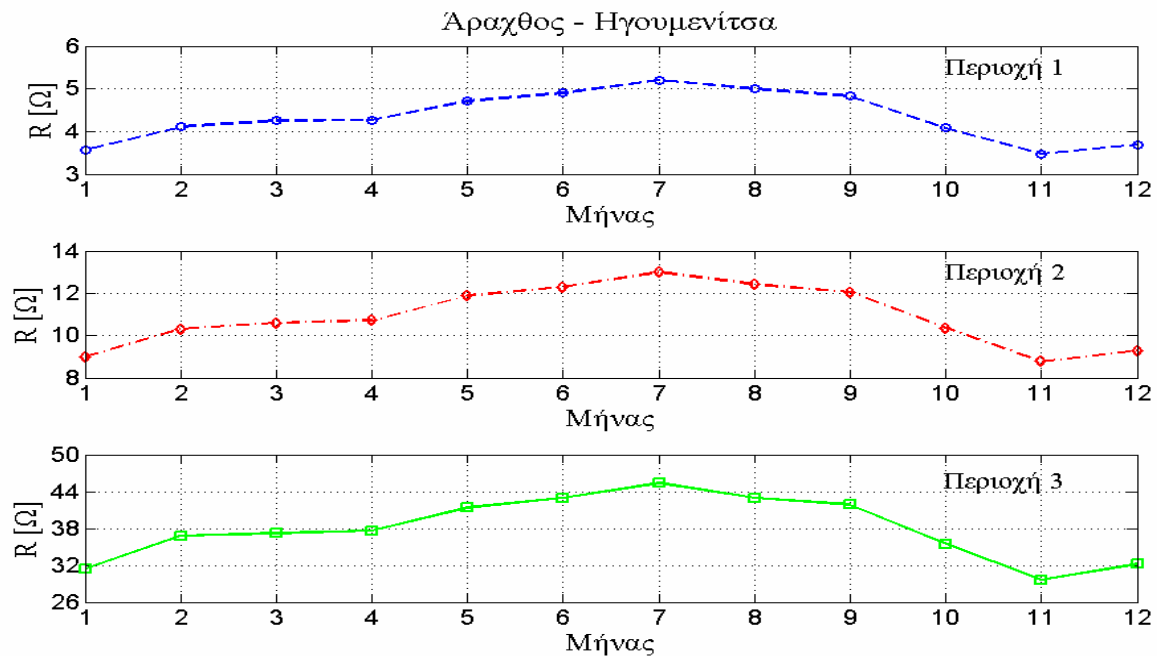


**Εικ. 5-1.** Ενδεικτική ετήσια μεταβολή της αντίστασης του εδάφους της γραμμής μεταφοράς Θεσσαλονίκη-Καρδιά για ένα ημερολογιακό έτος.





**Εικ. 5-2.** Ενδεικτική ετήσια μεταβολή της αντίστασης του εδάφους της γραμμής μεταφοράς Πύργος-Μεγαλόπολη II για ένα ημερολογιακό έτος.



**Εικ. 5-3.** Ενδεικτική ετήσια μεταβολή της αντίστασης του εδάφους της γραμμής μεταφοράς Αραχθος-Ηγουμενίτσα για ένα ημερολογιακό έτος.

Η μεταβολή της αντίστασης του εδάφους κατά τη διάρκεια του έτους μπορεί να προκληθεί λόγω των υψηλών θερμοκρασιών και της πολύ μικρής βροχόπτωσης το καλοκαίρι, σε αντίθεση με το χειμώνα που η μεταβολή της οφείλεται στις χαμηλότερες θερμοκρασίες και στην εντονότερη βροχόπτωση. Όποιες όμως και να είναι οι συνθήκες, η μεταβολή της αντίστασης του εδάφους είναι κάτι που θα πρέπει να συμπεριληφθεί είτε κατά το σχεδιασμό ενός νέου δικτύου είτε στη μελέτη συντήρησης και επέκτασης του υπάρχοντος δικτύου μεταφοράς και διανομής ηλεκτρικής ενέργειας.

Στο κεφάλαιο αυτό διερευνάται το πρόβλημα της αποτελεσματικής παραμετροποίησης και μοντελοποίησης της μεταβολής της αντίστασης του εδάφους χρησιμοποιώντας μοντέλα ARMA. Τα δεδομένα είναι πραγματικά, αντιπροσωπεύουν την ευρύτερη περιφέρεια του νομού Αττικής και μας παραχωρήθηκαν από το Ε.Μ.Π [124]. Όπως θα αποδειχτεί παρακάτω υπάρχει η δυνατότητα εφαρμογής *off – line* κάποιου μοντέλου ARMA στα δεδομένα αυτά. Μια σημαντική όμως παράμετρος στο ζήτημα της μοντελοποίησης των δεδομένων είναι το κατά πόσο χρήσιμο μπορεί να είναι το μοντέλο αυτό όταν τα δεδομένα περιέχουν υψηλό θόρυβο ή όταν χρειάζεται *on – line* μοντελοποίηση.


Για το σκοπό αυτό γίνεται μια σύγκριση ανάμεσα σε καταξιωμένα κριτήρια σχετικά με την επιτυχή αναγνώριση της τάξης και των συντελεστών μοντέλων ARMA υπό την επίδραση υψηλού θορύβου.

Συγκεκριμένα τα κριτήρια αυτά είναι τα *Corrected Akaike Criterion (AICC)*, *Akaike's Information Criterion (AIC)*, *Bayesian Information Criterion (BIC)* και τέλος ο Αλγόριθμος πολυ-μοντελικού Διαμελισμού (ή φίλτρο Λαϊνιώτη) *MMPF*. Τα συμπεράσματα αυτής της έρευνας μπορούν να αξιοποιηθούν από τον σχεδιαστή συστήματος μεταφοράς και διανομής ηλεκτρικής ενέργειας διότι η μεταβολή της αντίστασης του εδάφους επηρεάζει σημαντικά την απόδοση των συστημάτων ισχύος κατά τη διάρκεια ενός ημερολογιακού έτους.

## 5.2. Μοντελοποίηση των δεδομένων και σύγκριση κριτηρίων.

### 5.2.1 Μοντελοποίηση δεδομένων

Οι τιμές για την αντίσταση του εδάφους αφορούν την ευρύτερη περιοχή του νομού Αττικής. Η μέτρησή της περιλαμβάνει το διάστημα από το Σεπτέμβριο 2003 έως και το Δεκέμβριο του 2006 και έγινε από το Ε.Μ.Π [124]. Η μεταβολή της αντίστασης του εδάφους παρουσιάζεται στην εικόνα 5-4:



Εικ. 5-4. Μεταβολή της αντίστασης του εδάφους από 9<sup>ο</sup> 2003 – 12<sup>ο</sup> 2006.

Τα δεδομένα υπέστησαν επεξεργασία *off* – *line* και για τον προσδιορισμό του μοντέλου ARMA χρησιμοποιήθηκε το Matlab<sup>®</sup> καθώς και το λογισμικό εργαλείο *ARMASA* το οποίο είναι ελεύθερο προς δημόσια χρήση [129]. Το συγκεκριμένο λογισμικό εργαλείο έχει αναπτυχθεί από τον P. M. T. Broersen [121, 122], και εφαρμόζει ταυτόχρονα ανάλυση της συνάρτησης αυτοσυσχέτισης (*Automatic Autocorrelation Function Analysis*) καθώς και ανάλυση φάσματος (*spectrum analysis*), μια μέθοδο η οποία πληρεί τις προϋποθέσεις του «σχεδόν βέλτιστου κριτηρίου» (*near-optimal criterion*) [123, 124]. Σύμφωνα με τους δημιουργούς του *ARMASA* το λογισμικό αυτό εργαλείο μπορεί να δουλέψει εξίσου καλά τόσο για μικρό αριθμό παρατηρήσεων, όπως στην περίπτωση που εξετάζεται εδώ, όσο και για μεγαλύτερο. Προτείνει ένα βέλτιστο μοντέλο ARMA για τα δεδομένα ενώ

επιπρόσθετα παράγει και μια σειρά από άλλα πιθανά μοντέλα ARMA διαφορετικής τάξης.

Σύμφωνα λοιπόν με το *ARMASA* προέκυψε ένα μοντέλο ARMA(4,2) με τους ακόλουθους συντελεστές:


$$\mathbf{A}_1=[1], \mathbf{A}_2=[-1.0424], \mathbf{A}_3=[0.0050], \mathbf{A}_4=[-0.0659], \mathbf{B}_1=[1], \mathbf{B}_2=[-0.0171]. \quad (5-1)$$

### 5.2.2. Σύγκριση κριτηρίων

Το ερώτημα που προκύπτει μετά τη μοντελοποίηση των δεδομένων είναι το κατά πόσο χρήσιμο μπορεί να είναι το μοντέλο αυτό όταν τα δεδομένα περιέχουν υψηλό θόρυβο ή όταν χρειάζεται *on – line* μοντελοποίηση. Στα πραγματικά δεδομένα, εικ. 5-4, προστέθηκε θόρυβος με μήτρα διασποράς  $\mathbf{R} = [1.25]$ . Όπως είναι εμφανές τα νέα δεδομένα είναι εντελώς διαφοροποιημένα από τα παλιά, εικ 5-5. Με αυτά τα νέα δεδομένα θα πραγματοποιηθεί μια σύγκριση ανάμεσα σε καταξιωμένα κριτήρια σχετικά με την επιτυχή αναγνώριση της τάξης και των συντελεστών μοντέλων ARMA υπό την επίδραση υψηλού θορύβου. Συγκεκριμένα τα κριτήρια αυτά είναι τα *Corrected Akaike Criterion (AICC)*, *Akaike's Information Criterion (AIC)*, *Bayesian Information Criterion (BIC)* και τέλος ο Αλγόριθμος Πολύ-μοντελικού Διαμελισμού (ή φίλτρο Λαϊνιώτη) *MMPF*.

Οι εξισώσεις για τα κριτήρια *Corrected Akaike Criterion (AICC)*, *Akaike's Information Criterion (AIC)*, *Bayesian Information Criterion (BIC)* είναι οι (4-1), (3-10), (3-11) αντίστοιχα και η ανάλυσή τους έχει γίνει στα προηγούμενα κεφάλαια. Το ίδιο ισχύει και για τον Αλγόριθμο πολυ-μοντελικού Διαμελισμού (ή φίλτρο Λαϊνιώτη) *MMPF*.

Κάθε ένα από τα παραπάνω κριτήρια δοκιμάστηκε 100 φορές (100 Monte Carlo Runs) για τρία διαφορετικά σε μέγεθος σύνολα αρχικών δεδομένων, (50 παρατηρήσεις, 100 παρατηρήσεις, 150 παρατηρήσεις). Ο σκοπός είναι να διαπιστωθεί ποιο κριτήριο μπορεί με το μεγαλύτερο ποσοστό επιτυχίας να εκτιμήσει την τάξη και τους συντελεστές του μοντέλου (5-1), υπό την παρουσία υψηλού θορύβου.




Εικ. 5-5. 1<sup>η</sup> Εικόνα: Αντίσταση εδάφους αλλοιωμένη με θόρυβο. 2<sup>η</sup> Εικόνα: Σύγκριση μεταξύ των πραγματικών δεδομένων και εκείνων μετά την προσθήκη θορύβου.

### 5.2.3 Αποτελέσματα


Πραγματικοί Συντελεστές	Εκτιμώμενοι Συντελεστές			
	Κριτήρια:			
ARMA	MMPF	AICC	AIC	BIC
1	0.9990	0.9992	0.9542	0.9842
-1.0424	-1.0492	-0.923	-0.9342	-1.0310
0.0050	0.0047	0.0043	0.0037	0.0041
-0.0659	-0.0665	-0.0557	-0.0565	-0.0664
1	1	0.9989	0.9783	0.9874
-0.0171	-0.0176	-0.0169	-0.0198	-0.0152

Πίνακας 5-1. Εκτίμηση των παραμέτρων του μοντέλου ARMA (5-1).


Εικ. 5-6. Σύγκριση κριτηρίων για κάθε ένα από τα αρχικά σύνολα δεδομένων



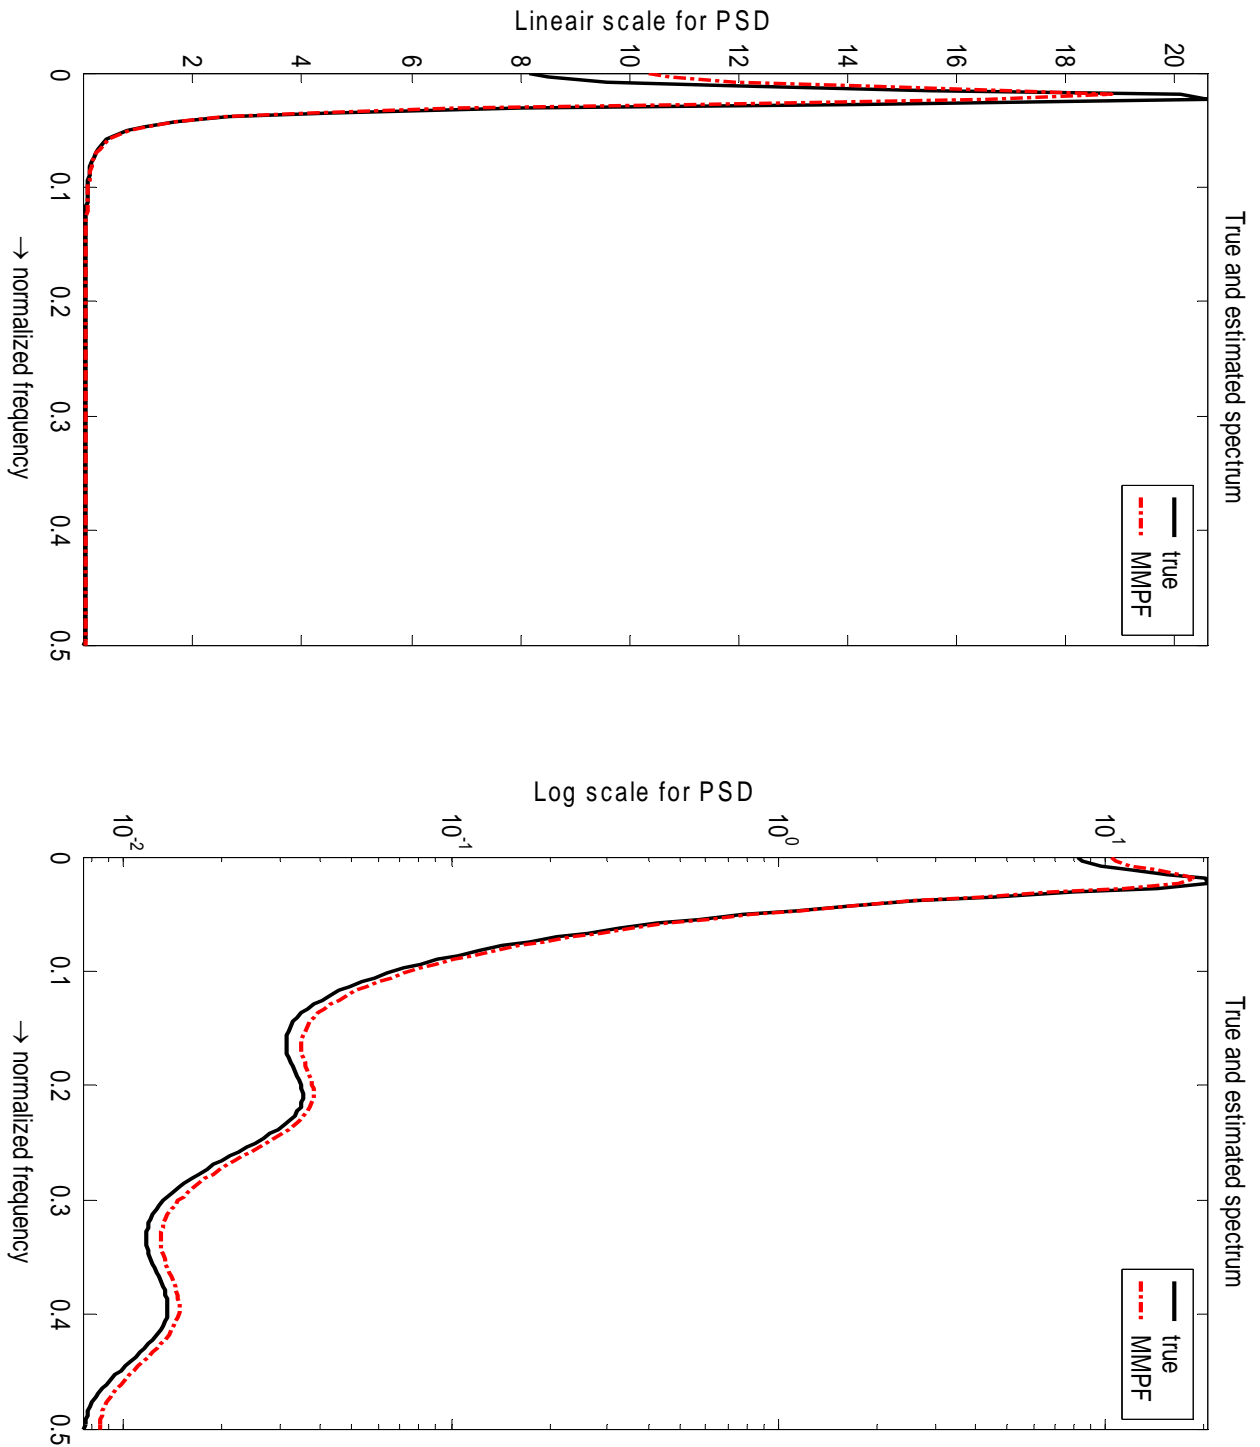
Εικ. 5-7. Ακολουθία των εκ των υστέρων πιθανοτήτων φίλτρου Λαϊνιώτη (MMPF)



Εικ. 5-8. Απόδοση του φίλτρου (Λαϊνιώτη - MMPF) Πολυμοντελικού Διαμελισμού.




**Εικ. 5-9.** Απόδοση του εκτιμώμενου μοντέλου μέσω του φίλτρου (Λαϊνιώτη - MMPF) Πολυμοντελικού Διαμελισμού. Οι εικόνες συγκρίνουν το πραγματικό και το εκτιμώμενο φάσμα (*power spectrum density PSD*). Οι δυο εικόνες είναι παρουσιάζουν το ίδιο γράφημα, αλλά η αριστερή έχει λογαριθμικό ψ-άξονα για ακριβέστερη σύγκριση.







Εικ. 5-10. Απόδοση του κριτηρίου AICC




Εικ. 5-11. Απόδοση του εκτιμώμενου μοντέλου μέσω του κριτηρίου AICC. Οι εικόνες συγκρίνουν το πραγματικό και το εκτιμώμενο φάσμα (*power spectrum density PSD*). Οι δυο εικόνες είναι παρουσιάζουν το ίδιο



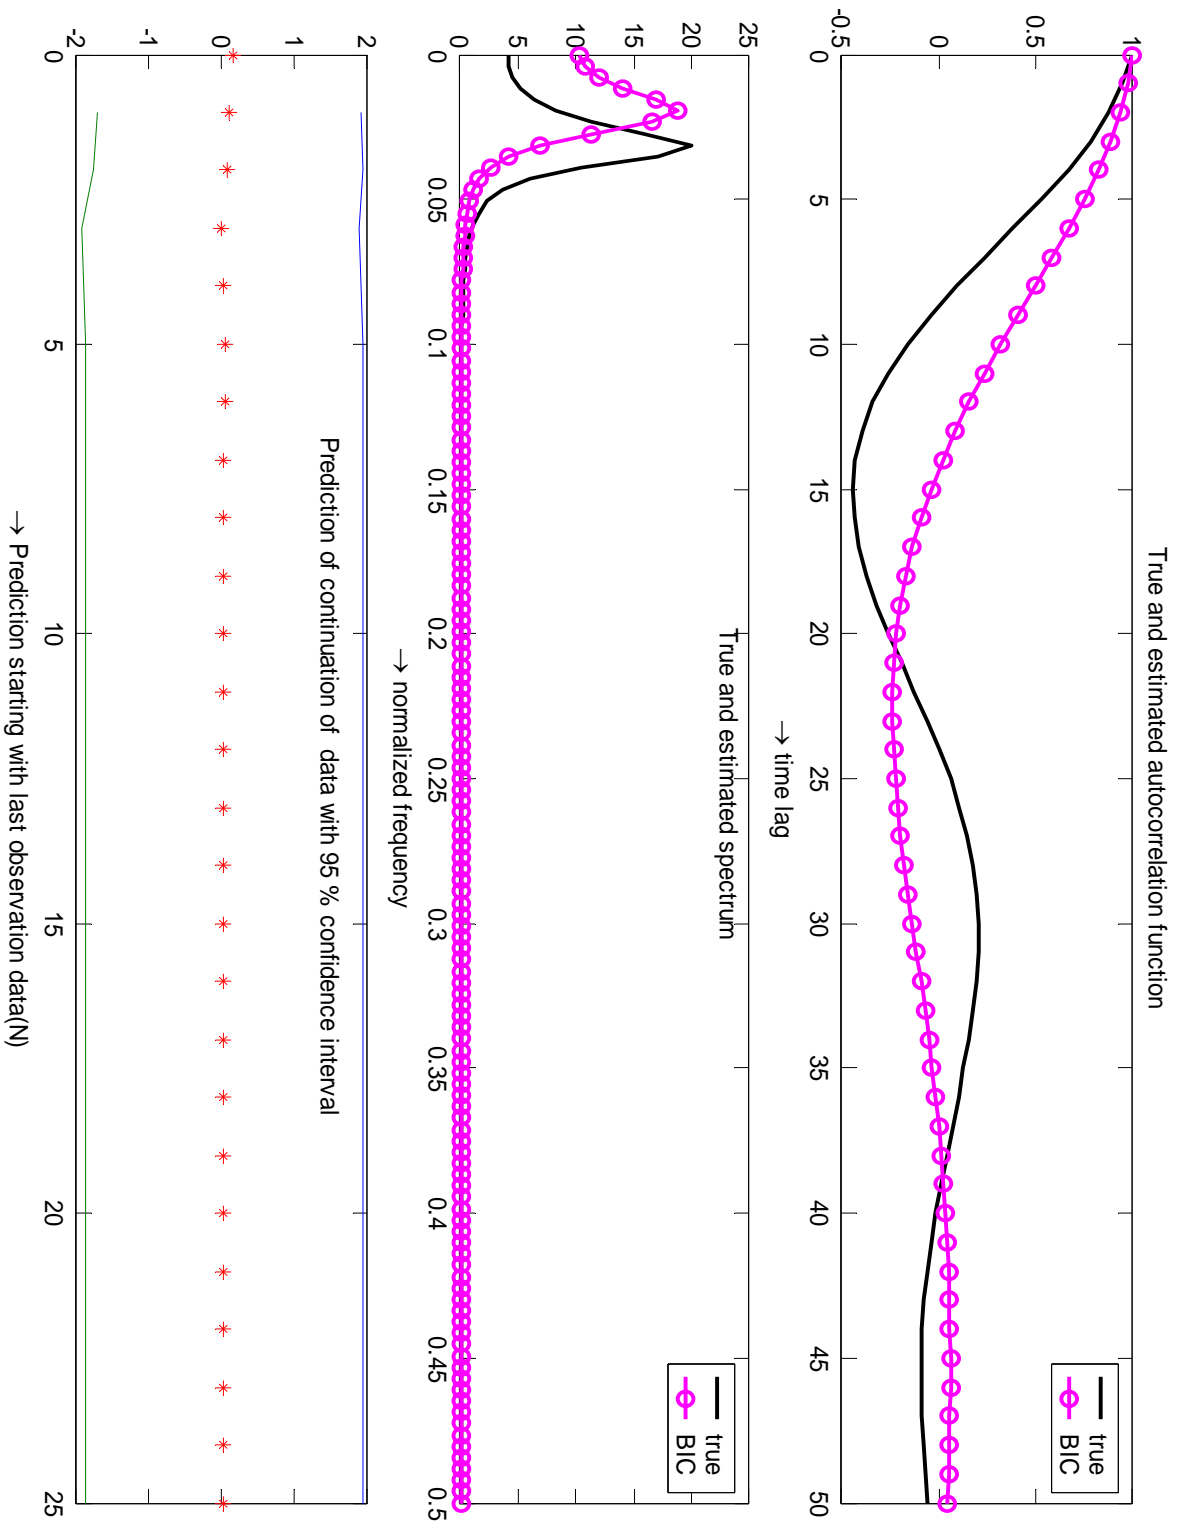
Εικ. 5-12. Απόδοση του κριτηρίου AIC




**Εικ. 5-13.** Απόδοση του εκτιμώμενου μοντέλου μέσω του κριτηρίου AIC. Οι εικόνες συγκρίνουν το πραγματικό και το εκτιμώμενο φάσμα (*power spectrum density PSD*). Οι δυο εικόνες παρουσιάζουν το ίδιο γράφημα, αλλά η αριστερή έχει λογαριθμικό  $\psi$ -άξονα για ακριβέστερη σύγκριση.



Εικ. 5-14. Απόδοση του κριτηρίου BIC



Εικ. 5-15. Απόδοση του εκτιμώμενου μοντέλου μέσω του κριτηρίου BIC. Οι εικόνες συγκρίνουν το πραγματικό και το εκτιμώμενο φάσμα (*power spectrum density PSD*). Οι δυο εικόνες είναι παρουσιάζουν το ίδιο γράφημα, αλλά η αριστερή έχει λογαριθμικό ψ-άξονα για ακριβέστερη σύγκριση.



### 5.3. Συμπεράσματα

Κοιτώντας συνολικά όλα τα αποτελέσματα μπορούμε να καταλήξουμε στο γενικό συμπέρασμα πως η απόδοση όλων των κριτηρίων κρίνεται ικανοποιητική παρόλο το υψηλό ποσοστό θορύβου που περιείχαν τα αρχικά δεδομένα. Ειδικότερα όμως μπορούμε να πούμε πως και σε αυτήν την περίπτωση ο Αλγόριθμος πολυ-μοντελικού Διαμελισμού (ή φίλτρο Λαϊνιώτη) *MMPF*, έχει ένα προβάδισμα σε σχέση με τα υπόλοιπα κριτήρια.

Κατ' αρχήν από την εικόνα 5-6, όπου γίνεται και η σύγκριση κριτηρίων είναι εμφανές πως εκτιμά την τάξη του μοντέλου και για τα τρία σύνολα αρχικών δεδομένων με 100% επιτυχία. Το ίδιο ποσοστό επιτυχίας βέβαια εμφανίζει και το κριτήριο *BIC* για το μεγαλύτερο όμως σύνολο δεδομένων, των 150 παρατηρήσεων. Και τα δυο άλλα κριτήρια, *AIC* & *AICC*, έχουν ικανοποιητική απόδοση για το εν λόγω σύνολο αρχικών δεδομένων, δηλαδή πάνω από 90%, όμως για τα μικρότερα σύνολα η απόδοσή τους υπολείπεται σημαντικά αυτής του *MMPF*.

Στον πίνακα 5-1 παρουσιάζονται οι παράμετροι των εκτιμώμενων μοντέλων βάσει κάθε κριτηρίου. Και πάλι βλέπουμε ότι το *MMPF* έχει το προβάδισμα αφού οι συντελεστές του εκτιμώμενου μοντέλου είναι πιο κοντά στους πραγματικούς σε σχέση με τα υπόλοιπα κριτήρια. Το γεγονός ότι το εκτιμώμενο μοντέλο βάσει του *MMPF* είναι το κοντινό στο πραγματικό δείχνουν και οι εικόνες 5-8 και 5-9. Όπως είναι εμφανές τόσο η συνάρτηση αυτοσυσχέτισης (*auto correlation function*) του εκτιμώμενου μοντέλου όσο και το γράφημα του φάσματος (*power spectrum density PSD*) είναι πολύ κοντά στο πραγματικό μοντέλο. Οι εικόνες 5-10 – 5-15 δείχνουν πως το αποτέλεσμα των υπόλοιπων κριτηρίων αποκλίνει περισσότερο από το πραγματικό μοντέλο σε σχέση με εκείνο του *MMPF*. Από τις εικόνες 5-14 & 5-15 είναι εμφανές πως μετά το *MMPF* το κριτήριο *BIC* είναι εκείνο με την αμέσως καλύτερη απόδοση.

## **Κεφάλαιο 6**

Περίληψη, Γενικά Συμπεράσματα, Παραπέρα  
Έρευνα



Στη μελέτη αυτή ασχοληθήκαμε με την επέκταση του αλγόριθμου πολύ-μοντελικού διαμελισμού, ο οποίος προτάθηκε από τον Δ. Γ. Λαϊνιώτη, σε πολυ-μεταβλητά (*multivariate - MV*) μοντέλα, ακολουθιακά (*AR - Autoregressive*) και μεικτών διεργασιών (*ARMA – AutoRegressive Moving Average*). Ο στόχος ήταν ο προσδιορισμός της τάξης των μοντέλων αυτών αλλά και η ακριβέστερη δυνατή εκτίμηση των παραμέτρων τους υπό την παρουσία έντονου θορύβου. Η δουλειά στον τομέα αυτό παρουσιάζεται με θεωρητικά μοντέλα στα κεφάλαια 1 και 3 αλλά και με πραγματικά δεδομένα στα κεφάλαια 4 και 5. Εκτός από τη θεωρητική αυτή επέκταση ο αλγόριθμος εφαρμόστηκε σε δυο πραγματικά προβλήματα, τον εντοπισμό δικτυακών ανωμαλιών, κεφάλαιο 2 και την πρόβλεψη της διακύμανσης του ηλεκτρικού φορτίου, κεφάλαιο 4.

Αναλυτικότερα στο 1<sup>ο</sup> κεφάλαιο παρουσιάστηκε η επέκταση του αλγόριθμου για την ταυτόχρονη αναγνώριση των παραμέτρων και της τάξης χρονικά αμετάβλητων *MV AR* μοντέλων ως επέκταση της υπάρχουσας μεθόδου που λειτούργησε επιτυχώς για τη βαθμωτή περίπτωση [30]. Η αξιολόγηση του προτεινόμενου αλγόριθμου έγινε μέσω της σύγκρισής του με άλλα καταξιωμένα κριτήρια επιλογής της τάξης *MV AR* μοντέλων, ονομαστικά AIC, AICC, BIC, H & Q, DC, MDC, και απέδειξε ότι μπορεί να αντιμετωπίσει το πρόβλημα χρησιμοποιώντας πάντα το μικρότερο δυνατό αρχικό σύνολο δεδομένων. Επίσης μέσω των ίδιων εξομοιώσεων αποδείχθηκε ότι ο αλγόριθμος αποδίδει εξίσου καλά ακόμα και όταν αυξάνει η πολυπλοκότητα του *MV AR* μοντέλου, ή όταν η τάξη  $\theta$  του μοντέλου είναι χρονικά μεταβαλλόμενη.

Στη συνέχεια στο 2<sup>ο</sup> κεφάλαιο χρησιμοποιήθηκαν πραγματικά δικτυακά δεδομένα από το Τ.Ε.Ι Αθηνών με σκοπό τη μοντελοποίηση της συμπεριφοράς του δικτύου αλλά και τον εντοπισμό των ανωμαλιών στη λειτουργία του. Για το πρώτο σκέλος, δηλαδή τη μοντελοποίηση, βασιστήκαμε σε παλαιότερα δεδομένα δικτυακής κίνησης και χρησιμοποιήθηκαν μοντέλα *SARIMA*. Για τον επιτυχή υπολογισμό του μοντέλου χρησιμοποιήθηκε επίσης το λογισμικό πακέτο *SPSS*<sup>®</sup>. Ο αλγόριθμος επεξεργάστηκε επιτυχώς τα πραγματικά δεδομένα και όπως έδειξαν

τα αποτελέσματα ανίχνευσε με επιτυχία τις αλλαγές, τις ασυνήθιστες διεργασίες και τα λάθη που περιέχονταν στο σύνολο των δεδομένων. Επιπλέον τα αποτελέσματα έδειξαν ότι ανταποκρίνεται πολύ γρήγορα στις αλλαγές αυτές και ότι θα μπορούσε να αποδώσει το ίδιο καλά σε πραγματικό χρόνο ακόμα και για διαστήματα δειγματοληψίας μικρότερα των 5 λεπτών.

Περαιτέρω δουλειά βασισμένη σε αυτά τα αποτελέσματα περιλαμβάνει:

- την εγγραφή και μοντελοποίηση και άλλων ποσοτήτων που μας δίνει το MIB του αναδρομολογητή και που συνδέονται άμεσα με την κίνηση του δικτύου καθώς και τα προβλήματα του,
- την ελαχιστοποίηση του χρόνου που μεσολαβεί μεταξύ δυο διαδοχικών δειγματοληψιών (*minimization of sampling interval*) με στόχο την απόκτηση καλύτερων χρόνων αντίδρασης,
- τη μοντελοποίηση της συμβατικής συμπεριφοράς του χρήστη (*normal user behaviour*) και
- τη μοντελοποίηση περισσότερων ασυνήθιστων δικτυακών συμπεριφορών και άλλων προβλημάτων.

Τα συμπεράσματα της έρευνας του 2<sup>ου</sup> κεφαλαίου μπορούν να χρησιμοποιηθούν από τους διαχειριστές του συστήματος του δικτύου με στόχο την ανίχνευση των ανωμαλιών αλλά και της κακής χρήσης του χρησιμοποιώντας απλά και εύκολα προσβάσιμα δεδομένα όπως είναι τα δεδομένα εκμετάλλευσης εύρους ζώνης. Επίσης η προτεινόμενη μέθοδος κρίνεται αποτελεσματική διότι είναι ικανή να προσαρμόζεται στις αλλαγές της κανονικής συμπεριφοράς ενώ ταυτόχρονα είναι σε θέση να αναγνωρίζει τις όποιες παραβατικές συμπεριφορές έχοντας ως αποτέλεσμα την ελαχιστοποίηση των λανθασμένων συναγερμών και την αύξηση της αξιοπιστίας του συστήματος.

Η έρευνα στο κεφάλαιο 3 είναι παρεμφερής με αυτή του 1<sup>ου</sup> κεφαλαίου. Ο αλγόριθμος της επιλογής της τάξης και εκτίμησης των τελεστών *MV AR* μοντέλων, επεκτάθηκε και εφαρμόστηκε για τον ίδιο σκοπό σε *MV ARMA* μοντέλα. Οι εξομοιώσεις απέδειξαν ότι η μέθοδος επιλέγει με επιτυχία τη σωστή, αθροιστικά,

τάξη του μοντέλου σε πολύ μικρό χρόνο και αναγνωρίζει με μεγάλη ακρίβεια τους τελεστές των  $MV ARMA$  μοντέλων που δοκιμάστηκαν. Η αξιολόγηση της απόδοσης του αλγόριθμου έγινε μέσω της σύγκρισής του με άλλα δυο καταξιωμένα κριτήρια, και πιο συγκεκριμένα τα  $AIC$ , και  $BIC$ , όπου και αποδεικνύεται ότι μπορεί να λειτουργήσει επιτυχώς χρησιμοποιώντας πάντα το μικρότερο αρχικό σύνολο δεδομένων. Επίσης τα αποτελέσματα των εξομοιώσεων δείχνουν ότι ο αλγόριθμος μπορεί να εντοπίσει τυχόν αλλαγές της τάξης του μοντέλου  $\theta$  σε πραγματικό χρόνο ακόμα και όταν η πολυπλοκότητα των μοντέλων αυξάνεται.

Το πρόβλημα που αντιμετωπίσαμε εδώ είναι το πώς θα γίνεται ο διαχωρισμός της τάξης  $p$  του  $AR$  μοντέλου από την τάξη  $q$  του μοντέλου  $MA$ . Μια λύση θα ήταν να επεξεργαστούμε 2 φορές τα δεδομένα, όμως με αυτόν τον τρόπο θα χάναμε το πλεονέκτημα του αλγόριθμου που είναι *one-pass*. Μια άλλη λύση είναι να υλοποιηθούν από την αρχή όσα υποφίλτρα χρειάζονται ώστε να καλυφθούν όλοι οι δυνατοί συνδυασμοί  $(p, q)$  της τάξης του μοντέλου  $ARMA$  [131]. Το τελευταίο είναι αρκετά δύσκολο να εφαρμοστεί σε πραγματικά προβλήματα, όπως αυτό του κεφαλαίου 4. Ο λόγος είναι πως καθώς η τάξη του μοντέλου  $ARMA$  μεγαλώνει θα πρέπει να υλοποιείται όλο και μεγαλύτερος αριθμός υποφίλτρων γεγονός που αυξάνει σημαντικά τον υπολογιστικό φόρτο. Για παράδειγμα εάν η τάξη του μοντέλου είναι  $(3,6)$  σημαίνει ότι υπάρχουν 36 συνδυασμοί, άρα 36 αρχικά φίλτρα. Επίσης όταν έχουμε να κάνουμε με πραγματικά δεδομένα είναι πολύ δύσκολο να προκαθορίσουμε από την αρχή τα όρια στα οποία θα κυμαίνεται η τάξη του μοντέλου. Αυτό που έγινε σε αυτήν την μελέτη είναι η εκτίμηση της τάξης του μοντέλου  $\theta$  ως το άθροισμα των  $p, q$ . Μια λύση στο πρόβλημα αυτό και ταυτόχρονα πρόταση για παραπέρα έρευνα είναι η τροποποίηση των εξισώσεων (3-2) & (3-3) ή η χρησιμοποίηση υβριδικών αλγόριθμων [49, 92].

Στο 4<sup>ο</sup> κεφάλαιο διερευνήθηκε το πρόβλημα της αποτελεσματικής παραμετροποίησης, μοντελοποίησης και εκτίμησης της ζήτησης του ηλεκτρικού φορτίου χρησιμοποιώντας μοντέλα  $ARMA$ . Τα δεδομένα που χρησιμοποιήθηκαν είναι πραγματικά και μας χορηγήθηκαν ευγενικά από τη Δ.Ε.Η. Α.Ε. [97].

Στο πρώτο μέρος του κεφαλαίου αυτού πραγματοποιήθηκε η μοντελοποίηση της ζήτησης της διακύμανσης του ηλεκτρικού φορτίου μέσω ενός μοντέλου ARMA, χρησιμοποιώντας τη μέθοδο των Nowicka-Zagrajek και Weron [106, 107], καθώς και το εργαλείο του MATLAB® *Modeling and Forecasting Electricity Loads and Prices (MFE)* το οποίο είναι ελεύθερο για δημόσια χρήση [115]. Η συμπεριφορά του τελικού μοντέλου κρίνεται επαρκής και ικανοποιητική βάση μιας σειράς στατιστικών κριτηρίων. Στη συνέχεια τα επεξεργασμένα δεδομένα εμπλουτίστηκαν με υψηλό θόρυβο και έτσι δημιουργήθηκε μια εντελώς διαφοροποιημένη χρονική σειρά. Τα νέα αυτά δεδομένα χρησιμοποιήθηκαν για την αξιολόγηση του αλγόριθμου Λαϊνιώτη μέσω της σύγκρισής του με τα ακόλουθα τρία κριτήρια, *Corrected Akaike Criterion (AICC)*, *Akaike's Information Criterion (AIC)*, *Bayesian Information Criterion (BIC)*. Από τη σύγκριση αποδείχθηκε ότι το φίλτρο Λαϊνιώτη (*MMPF*) είναι ικανό να εκτιμήσει γρήγορα και με απόλυτη επιτυχία την αθροιστική τάξη του μοντέλου ( $p+q$ ) καθώς και τους συντελεστές χρησιμοποιώντας το μικρότερο από τα αρχικά σύνολα δεδομένων.

Το επόμενο στάδιο αφορούσε την εφαρμογή και των τεσσάρων προαναφερθέντων κριτηρίων για την εκτίμηση της διακύμανσης της ζήτησης του φορτίου χρησιμοποιώντας πραγματικά δεδομένα. Βάση των αποτελεσμάτων είναι εμφανές πως η απόδοση όλων κρίνεται ικανοποιητική, με το φίλτρο Λαϊνιώτη (*MMPF*) να υπερέχει λόγω του ότι παρουσιάζει το μικρότερο μέσο εκατοστιαίο λάθος της απόλυτης τιμής *MAPE*, 1.87%.

Ακολούθησε η εβδομαδιαία εκτίμηση της διακύμανσης του φορτίου καθώς και η ημερήσια εκτίμηση της μέγιστης ζήτησης προσθέτοντας όμως στις συγκρινόμενες μεθόδους και τα νευρωνικά δίκτυα. Μελετώντας τα αποτελέσματα μπορούμε να καταλήξουμε στο συμπέρασμα πως όλες οι μέθοδοι απέδωσαν ικανοποιητικά με το φίλτρο Λαϊνιώτη μαζί με το Νευρωνικό Δίκτυο να παρουσιάζουν το μικρότερο μέσο εκτιμώμενο λάθος.

Αυτό το οποίο παρατηρήθηκε είναι το γεγονός πως όλες οι μέθοδοι παρουσίασαν το μεγαλύτερο λάθος για την εκτίμηση του φορτίου κατά τη διάρκεια του

Σαββατοκύριακου. Αυτό πρέπει να οφείλεται στο ότι η συμπεριφορά του φορτίου κατά τη διάρκεια του Σαββατοκύριακου δεν είναι καθαρά *Gaussian*, κάτι που δεν λήφθηκε υπ' όψιν στο πρώτο στάδιο της επεξεργασίας των δεδομένων που είχε ως στόχο την εύρεση ενός μοντέλου *ARMA*. Σε αυτές τις περιπτώσεις το Νευρωνικό δίκτυο και η μέθοδος *AICC* υπερέχουν αφού εμφανίζουν το μικρότερο λάθος.

Με στόχο να ξεπεράσουμε το παραπάνω πρόβλημα δοκιμάστηκε η μοντελοποίηση της διακύμανσης του ηλεκτρικού φορτίου μέσω μοντέλου τύπου *SARIMA* όπως και στο 2ο κεφάλαιο. Και πάλι μοντελοποιήθηκε τόσο η περιοδική ομαλή συμπεριφορά του φορτίου όσο και περιπτώσεις ανωμαλιών. Από τα αποτελέσματα προκύπτει ότι το φίλτρο Λαϊνιώτη επεξεργάστηκε επιτυχώς τα πραγματικά δεδομένα και εντόπισε επιτυχώς και πολύ γρήγορα τις αλλαγές, που περιέχονταν στο σύνολο των δεδομένων. Επίσης το λάθος της μεθόδου όσον αφορά την εκτίμηση του φίλτρου δεν ξεπερνά το 2.5%, γεγονός που σημαίνει ότι η απόδοσή του είναι εντός των σύγχρονων απαιτήσεων.

Περαιτέρω έρευνα στο κομμάτι αυτό περιλαμβάνει τη χρησιμοποίηση διαστημάτων δειγματοληψίας μικρότερων της 1 ώρας με στόχο την εξαιρετικά βραχυπρόθεσμη εκτίμηση του φορτίου (*ultra-short term load estimation*) κάτι το οποίο μελετάται την τελευταία τριετία, αλλά και η χρησιμοποίηση των πραγματικών αυτών δεδομένων με υβριδικές τεχνικές.

Τα συμπεράσματα της έρευνας του κεφαλαίου μπορούν να αξιοποιηθούν στην περαιτέρω μελέτη της διακύμανσης του ηλεκτρικού φορτίου καθώς και στην πρόβλεψη της τιμής της ηλεκτρικής μονάδας

Στο τελευταίο κεφάλαιο μελετήθηκε το πρόβλημα της αποτελεσματικής παραμετροποίησης, μοντελοποίησης της μεταβολής της αντίστασης του εδάφους χρησιμοποιώντας μοντέλα *ARMA* και η αξιολόγηση του προκύπτοντος μοντέλου όταν τα δεδομένα περιέχουν υψηλό θόρυβο ή όταν χρειάζεται *on – line* μοντελοποίηση.

Για το σκοπό αυτό έγινε μια σύγκριση ανάμεσα σε καταξιωμένα κριτήρια για την επιτυχή αναγνώριση της τάξης και των συντελεστών μοντέλων *ARMA* υπό την επίδραση υψηλού θορύβου, δηλαδή τα *Corrected Akaike Criterion (AICC)*, *Akaike's Information Criterion (AIC)*, *Bayesian Information Criterion (BIC)*, και τον Αλγόριθμο πολυ-μοντελικού Διαμελισμού (ή φίλτρο Λαϊνιώτη) *MMPF*.

Εξετάζοντας συνολικά τα αποτελέσματα μπορούμε να συμπεράνουμε πως η απόδοση όλων των κριτηρίων κρίνεται ικανοποιητική παρόλο το υψηλό ποσοστό θορύβου που περιείχαν τα αρχικά δεδομένα. Ειδικότερα όμως ο Αλγόριθμος πολυ-μοντελικού Διαμελισμού (ή φίλτρο Λαϊνιώτη) *MMPF*, έχει ένα προβάδισμα σε σχέση με τα υπόλοιπα κριτήρια λόγω της μεγαλύτερης ακρίβειας που παρουσιάζει στη εκτίμηση των συντελεστών του μοντέλου ακόμα και για μικρό αριθμό αρχικών δειγμάτων. Επίσης κρίνοντας από το γράφημα του φάσματος ισχύος παρατηρούμε ότι το εκτιμώμενο μοντέλο μέσω του συγκεκριμένου αλγόριθμου είναι το πιο κοντινό στο πραγματικό.

Τα συμπεράσματα της έρευνας του 5<sup>ου</sup> κεφαλαίου μπορούν να αξιοποιηθούν από τον σχεδιαστή συστήματος μεταφοράς και διανομής ηλεκτρικής ενέργειας διότι η μεταβολή της αντίστασης του εδάφους επηρεάζει σημαντικά την απόδοση των συστημάτων ισχύος κατά τη διάρκεια ενός ημερολογιακού έτους.

# ΠΑΡΑΡΤΗΜΑ Α

## ΤΕΧΝΗΤΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

**T**α τεχνητά νευρωνικά δίκτυα είναι μέθοδοι που επεξεργάζονται πληροφορίες. Συνήθως εφαρμόζονται χρησιμοποιώντας ηλεκτρονικά στοιχεία ή λογισμικό προσομοίωσης. Ο κύριος σκοπός των νευρωνικών δικτύων είναι η βελτίωση της ικανότητας των υπολογιστών να πάρουν αποφάσεις, με έναν τρόπο παρόμοιο με αυτό του ανθρώπινου εγκεφάλου, για τον οποίο οι συμβατικοί υπολογιστές είναι ακατάλληλοι. Τα νευρωνικά δίκτυα αποτελούνται από ένα μεγάλο αριθμό στοιχείων επεξεργασίας που αποκαλούνται νευρώνες ή κόμβοι. Τα στοιχεία επεξεργασίας συνδέονται μεταξύ τους με άμεσες συνδέσεις γνωστές ως συναπτικά βάρη. Ένα από τα σημαντικότερα χαρακτηριστικά γνωρίσματα των τεχνητών νευρωνικών δικτύων είναι η ικανότητά τους να προσαρμόζονται σε διαφορετικά περιβάλλοντα αλλάζοντας τις τιμές των συνδέσεών τους.

Τα νευρωνικά δίκτυα έχουν πολλά και σημαντικά γνωρίσματα. Αποτελούνται από έναν αριθμό αλληλοσυνδεδεμένων νευρώνων με μη γραμμικές συναρτήσεις μεταφοράς έχοντας τη δυνατότητα να πραγματοποιούν μη γραμμικές απεικονίσεις. Αποτελούν ισχυρές μεθόδους υπολογισμών λόγω της ευμεγέθους παράλληλης δομής τους, ενώ ένα άλλο σημαντικό χαρακτηριστικό γνώρισμά τους είναι η δυνατότητά τους να μαθαίνουν και να γενικεύουν. Το νευρωνικό δίκτυο εκπαιδεύεται με ένα μέρος των στοιχείων, που αποκαλείται σύνολο εκπαίδευσης, χρησιμοποιώντας είτε εποπτευόμενους είτε μη εποπτευόμενους αλγορίθμους μάθησης. Το εκπαιδευμένο δίκτυο χρησιμοποιείται στη συνέχεια για να προβλέψει τιμές που δεν περιλαμβάνονται στο σύνολο εκπαίδευσης. Στις περισσότερες περιπτώσεις, τα εκπαιδευμένα δίκτυα μπορούν να παρέχουν μία αποδεκτή γενίκευση. Όλα αυτά τα χαρακτηριστικά γνωρίσματα έδωσαν τα κίνητρα στους ερευνητές να μελετήσουν και να εφαρμόσουν τα νευρωνικά δίκτυα στους ψηφιακούς υπολογιστές.

Τα τεχνητά νευρωνικά δίκτυα έχουν την ικανότητα να «μαθαίνουν» αυτόματα προσεγγιστικές σχέσεις μεταξύ εισόδων και εξόδων, ανεξάρτητα από το μέγεθος και την πολυπλοκότητα του προβλήματος. Στην παρούσα μελέτη κατασκευάστη-



κε ένα τεχνητό νευρωνικό δίκτυο, λαμβάνοντας υπ' όψιν και οικονομικούς παράγοντες όπως, το εθνικό ακαθάριστο προϊόν, το ακαθάριστο εγχώριο προϊόν και το σύνολο του πληθυσμού. Οι παράγοντες αυτοί επηρεάζουν κυρίως την μακροπρόθεσμη εκτίμηση του φορτίου όμως δεν μπορούν να αγνοηθούν. Γι' αυτό το λόγο υπολογίστηκε ένας συντελεστής συμμετοχής  $F$  (*contribution factor*) βασισμένος σε πραγματικά δεδομένα που αφορούν τους τρεις προαναφερθέντες οικονομικούς παράγοντες [130]. Ως προς τη δημιουργία και την εκπαίδευση του προτεινόμενου δικτύου χρησιμοποιήθηκε το υπολογιστικό πρόγραμμα MATLAB και συγκεκριμένα η εργαλειοθήκη Νευρωνικών Δικτύων. Για να καταλήξουμε όμως στο προτεινόμενο σε αυτή τη διδακτορική διατριβή μοντέλο, προηγήθηκε διεξοδική εξέταση και μελέτη πολλών μοντέλων επιλέγοντας το μοντέλο εκείνο που παρουσίασε την καλύτερη ικανότητα γενίκευσης, είχε συμπαγή μορφή, γρήγορη διαδικασία εκπαίδευσης και χαμηλή κατανάλωση υπολογιστικής μνήμης.

Πιο αναλυτικά, έχοντας αποφασίσει τον αριθμό των εισόδων και εξόδων του δικτύου πέντε παράμετροι που συμβάλλουν σημαντικά στη διακύμανση της ζήτησης του ηλεκτρικού φορτίου επιλέχθηκαν ως εισοδοί στο νευρωνικό δίκτυο. Οι παράμετροι αυτές είναι: θερμοκρασία περιβάλλοντος, σχετική υγρασία, η ημέρα της εβδομάδας, ο μήνας και ο συντελεστής συμμετοχής  $F$  που έχει ήδη αναφερθεί. Ως έξοδος του νευρωνικού δικτύου ορίστηκε η ζήτηση του ηλεκτρικού φορτίου. Τόσο τα δεδομένα εισόδου, όσο και τα δεδομένα εξόδου αποτελούν είτε πραγματικά καταγεγραμμένα δεδομένα, είτε εκτιμώμενα δεδομένα, βασισμένα σε πραγματικές μετρήσεις. Πιο συγκεκριμένα, η ημερήσια θερμοκρασία περιβάλλοντος και η σχετική υγρασία έχει διατεθεί από την Εθνική Μετεωρολογική Υπηρεσία [135]. Η εκτίμηση του συντελεστή συμμετοχής  $F$  γίνεται βάσει πραγματικών στατιστικών στοιχείων από την Εθνική Στατιστική Υπηρεσία και το Υπουργείο Οικονομίας και Οικονομικών [132, 133]. Στις υπόλοιπες εισόδους, δηλαδή την ημέρα της εβδομάδας και το μήνα, αντιστοιχίζονται προσεκτικά επιλεγμένοι συντελεστές βάρους. Τέλος όσον αφορά την έξοδο, δηλαδή τη διακύμανση της ζή-

τησης του ηλεκτρικού φορτίου αυτή διατίθεται από τη ΔΕΗ Α.Ε. και τη Ρυθμιστική Αρχή Ενέργειας [97, 134].

Χρησιμοποιώντας το δίκτυο *MLP (Mutli-Layer Perceptron)*, το επόμενο βήμα ήταν ο καθορισμός του αριθμού των κρυμμένων στρωμάτων, του αριθμού των νευρώνων σε κάθε στρώμα, της μεθόδου εκπαίδευσης και της συνάρτησης μεταφοράς. Έχοντας υπόψη ότι ένα κρυμμένο στρώμα είναι επαρκές για γραμμικά διαχωρίσιμα δεδομένα εισόδου, ενώ περισσότερα κρυμμένα στρώματα χρησιμοποιούνται για μη γραμμικά διαχωρίσιμα δεδομένα [136], στην παρούσα εργασία, δοκιμάστηκαν μοντέλα νευρωνικών δικτύων με μέχρι και δύο κρυμμένα στρώματα. Οι δυο μέθοδοι εκπαίδευσης (*Gradient Descent* και *Levenberg – Marquardt*) και οι τρεις συναρτήσεις μεταφοράς (*Hyperbolic Tangent Sigmoid*, *Logarithmic Sigmoid*, και *Hard-Limit*) που δοκιμάστηκαν στα μοντέλα που κατασκευάστηκαν, επιλέχθηκαν από το σύνολο των έτοιμων μεθόδων και συναρτήσεων της εργαλειοθήκης Νευρωνικών Δικτύων του MATLAB.

Στη συνέχεια πραγματοποιήθηκαν πολλές διαδοχικές δοκιμές νευρωνικών μοντέλων τα οποία και αποτελούσαν συνδυασμούς ενός ή δύο κρυμμένων στρωμάτων (με εσωτερική μεταβολή στον αριθμό των νευρώνων (από 3 έως 20) προκειμένου να βρεθεί για πόσους νευρώνες παρουσιαζόταν ελάχιστο σφάλμα), των δύο μεθόδων εκπαίδευσης και των τριών συναρτήσεων μεταφοράς. Ο αριθμός των εποχών (επαναλήψεων), ο οποίος και αναπαριστά ένα σύνολο διανυσμάτων εκπαίδευσης του δικτύου για τον υπολογισμό νέων βαρών και όρων πόλωσης, διατηρούταν σταθερός και ίσος με 10000.

Τα δεδομένα που χρησιμοποιήθηκαν για την κατασκευή των μοντέλων και για κάθε μία από τις πέντε εισόδους και μία έξοδο του δικτύου ήταν χίλια τετρακόσια εξήντα και αφορούν την ημερήσια μέγιστη ζήτηση ηλεκτρικού φορτίου μιας περιόδου τεσσάρων ετών (2002-2005). Από τα δεδομένα αυτά, το 80% των δεδομένων (δηλαδή χίλια εκατόν εξήντα οχτώ δεδομένα) χρησιμοποιήθηκαν στην εκπαιδευτική διαδικασία ενώ το υπόλοιπο 20% (δηλαδή διακόσια ενενήντα δύο δεδομένα) χρησιμοποιήθηκαν για τον έλεγχο του δικτύου. Σε κάθε επανάληψη 10%

των δεδομένων εκπαίδευσης (δηλαδή εκατόν δέκα έξι δεδομένα) απομακρύνονταν τυχαία από το εκπαιδευτικό σύνολο υπολογίζοντας το σφάλμα επικύρωσης. Η εκπαιδευτική διαδικασία επαναλαμβανόταν έως ότου το μέσο τετραγωνικό σφάλμα ανάμεσα στα πραγματικά και επιθυμητά δεδομένα εξόδου φτάσει το 1% ή έως ότου ολοκληρωθεί ο μέγιστος αριθμός επαναλήψεων που έχει οριστεί (10000 στην παρούσα εφαρμογή).

Από όλα τα μοντέλα που δοκιμάστηκαν (πραγματοποιώντας τις διαδικασίες εκπαίδευσης, επικύρωσης και ελέγχου), επιλέχθηκε το μοντέλο με τα ακόλουθα χαρακτηριστικά: ένα κρυμμένο στρώμα αποτελούμενο από δεκαοκτώ νευρώνες, μέθοδος εκπαίδευσης η Levenberg - Marquardt και συνάρτηση μεταφοράς η Hyperbolic Tangent Sigmoid, ως το κατεξοχήν κατάλληλο και ακριβέστερο για την εκτίμηση της ζήτησης του ηλεκτρικού φορτίου. Το μοντέλο αυτό επιλέχθηκε σε σύγκριση με τα άλλα που δοκιμάστηκαν λόγω της καλύτερης ικανότητας γενίκευσής του, τη συμπαγή μορφή του, τη γρήγορη διαδικασία εκπαίδευσής του και την κατανάλωση μικρής υπολογιστικής μνήμης.

## BIBΛΙΟΓΡΑΦΙΑ

- [1] M.B. Priestly, Spectral Analysis and Time Series, Ac. Press, London, 1981.
- [2] R.E. Kalman, A new approach to the linear filtering and prediction problems, *Journal of Basic Engineering, Trans. of the ASME*, vol 82, pp. 35-45, 1960.
- [3] R.E. Kalman, R.S. Bucy, New results in linear filtering and prediction theory, *Journal of Basic Engineering, Trans. of the ASME*, vol 83, pp. 95-108, 1961.
- [4] L. Ljung, T. Söderström, Theory and practice of recursive identification, MIT Press, Cambridge, ISBN 026212095X, 1983.
- [5] P.C. Young, Recursive estimation and time series analysis, Springer Verlag, Berlin, ISBN 0387136770, 1984.
- [6] E.J. Hannan, The estimation of mixed moving average autoregressive systems, *Biometrika*, vol 56, pp. 579-563, 1969.
- [7] G.E.P. Box, G.M. Jenkins, Time series analysis forecasting and control, Prentice Hall, Englewood Cliffs, New Jersey, ISBN:--13-905100-7, 1976.
- [8] H. Akaike, Fitting autoregressive models for prediction, *Ann. Inst. Stat. Math.*, vol. 21, pp. 243–247, 1969.
- [9] P. Whittle, Hypothesis Testing and Time Series Analysis, Almqvist & Wiksell, Upsala, 1951.
- [10] J.S. Bendat, A.G. Piersol, Random data-Analysis and measurement procedures, John Wiley & Sons, New York, ISBN: 0-471-04000-2, 1986.
- [11] J.W. Cooley, J.W. Tukey, An algorithm for the machine calculation of complex Fourier Series, *Mathematics of Computation*, vol. 19, pp. 297-301, 1965.
- [12] S.M. Kay, Modern spectral estimation-Theory and application, Prentice Hall, Englewood Cliffs, New Jersey, ISBN: 0-13-598582-X, 1988.
- [13] J.K. Thompson, and D.R. Tree, Leakage error in Fast Fourier analysis, *Journal of Sound and Vibration*, vol. 71, Issue 4, pp. 531-544, 1980.
- [14] C.W. Anderson, E.A. Stolz, S. Shumsunder, Multivariate autoregressive models for classification of spontaneous electroencephalographic signals during mental tasks, *IEEE Trans. Biomedical Eng.*, vol. 45, pp. 277–286, 1998.

- [15] J. Li, G. Liu, and P. Stoica, Moving target feature extraction for airborne high-range resolution phased-array radar, *IEEE Trans. Signal Processing*, vol. 49, pp. 277–289, 2001.
- [16] J.C. Luby and D.W. Lytle, Autoregressive modelling of nonstationary multibeam sonar reverberation, *IEEE Journal of Oceanic Eng.*, vol. OE–12, no. 1, pp. 116–129, 1987.
- [17] F. Miwakeichi *et. al*, Impulse response function based on multivariate AR model can differentiate focal hemisphere in temporal lobe epilepsy, *Epilepsy Research*, vol. 61, Issues 1-3, pp. 73-87, 2004.
- [18] Xiao Hu, Valeriy Nenov, Multivariate AR modelling of electromyography for the classification of upper arm movements, *Clinical Neurology* 115, pp. 1276-1287, Elsevier, 2004.
- [19] G. Schwarz, Estimation of the dimension of the model, *Ann. Statist.*, vol. 6, pp. 461–464, 1978.
- [20] J. Rissanen, Modelling by shortest data description, *Automatica*, vol. 14, pp. 465–471, 1978.
- [21] J. Rissanen, A predictive least squares principle, *IMA J. Math. Contr. Inform.*, vol. 3, pp. 211–222, 1986.
- [22] M. Wax, Order selection for AR models by predictive least squares, *IEEE Trans. Acoust., Speech, Signal Processing*, vol. 36, pp. 581–588, 1988.
- [23] E.G. Hannan and B.G. Quinn, The determination of the order of an autoregression, *J. R. Stat. Soc., ser. B*, vol. 41, no. 2, pp. 190–195, 1979.
- [24] P.J. Brockwell and R.A. Davis, *Time series: Theory and methods*, 2nd Edition, Springer-Verlag, New York, pp. 432, 1991.
- [25] C.M. Hurvich and C.L. Tsai, Regression and time series model selection in small samples, *Biometrika*, 76, (2), pp. 297–307, 1989.
- [26] C. M. Hurvich and C. L. Tsai, A corrected Akaike Information criterion for vector autoregressive model selection, *J. Time Series Anal.*, 14, pp. 271-380, 1991.
- [27] C. Chen, R.A. Davis, P.J. Brockwell and Z.D. Bai, Order determination for autoregressive processes using resampling methods, *Statistica Sinica*, 3 (1993), 481-500.
- [28] Stijn de Waele and Piet M. T. Broersen, Order selection for vector autoregressive models, *IEEE Trans. Sig. Proc.* vol. 51, 2003.

- [29] H. Lutkepohl, Comparison of criteria for estimating the order of a vector AR process, *J. Time Ser. Anal.* 6, pp. 35-52, vol. 6, 1985.
- [30] S. K. Katsikas, S. D. Likothanassis and D. G. Lainiotis, AR model identification with unknown process order, *IEEE Trans. Acoustics, Speech and Signal Processing*, vol. 38, pp. 872-876, 1990.
- [31] A. Neumaier and T. Schneider Estimation of parameters and eigenmodes of multivariate autoregressive models, *ACM Trans. Math. Soft.* vol. 27, pp. 27-57, 2001.
- [32] C.C. Chen, R.A. Davis and P.J. Brockwell, Order determination for multivariate autoregressive processes using re-sampling methods, *Journal of Multivariate Analysis* 57, 175-190, 1996.
- [33] D.G. Lainiotis, Partitioning: A unifying framework for adaptive systems I: Estimation, *Proc. IEEE*, vol. 64, pp. 1126-1143, 1976.
- [34] \_\_\_\_\_, Partitioning: A unifying framework for adaptive systems II: Control, *Proc. IEEE*, vol. 64, pp. 1182-1198, 1976.
- [35] \_\_\_\_\_, Optimal adaptive estimation: Structure and parameter adaptation, *IEEE Trans. Automat. Contr.*, vol. AC-16, pp. 160-170, 1971.
- [36] A.P. Sage and G.W. Husa, Adaptive filtering with unknown prior statistics, in *Proc. Joint. Automatic Control Conf.*, Boulder, Colorado, pp. 760-769, 1969.
- [37] S.K. Katsikas, A.K. Leros, D.G. Lainiotis, Passive tracking of a maneuvering target: an adaptive approach, *Signal Processing, IEEE Transactions on*, vol 42, Issue 7, pp. 1820-1825, 1994
- [38] D.G. Lainiotis, I.A. Marinitis, S.K. Katsikas, Adaptive nonlinear algorithms for radar tracking with roll angle measurements of maneuvering targets, *Electrotechnical Conference, Proceedings of 7th Mediterranean*, vol 1, pp. 96-100, 1994
- [39] V.C. Moussas, S.D. Likothanassis, S.K. Katsikas and A.K. Leros, Adaptive On-Line Multiple Source Detection, *Acoustics, Speech and Signal Processing, Proceeding, (ICASP '05), IEEE International Conference on*, vol. 4, March 18-23, pp. 1029-1032, 2005.
- [40] V.C. Moussas and S.Sp. Pappas, Adaptive Network Anomaly Detection Using Bandwidth Utilization Data, *Proceedings of the 1<sup>st</sup> International Conference on Experiments/Processes/System Modelling/Simulation/Optimization*, Athens, 6-9 July, 2005.

- [41] V.C. Moussas and S.K. Katsikas, A multi-model approach to fatigue crack growth monitoring and prediction, 12<sup>th</sup> Int. Workshop on Systems, Signals & Image Processing, 22-24 Sept, Chalkida, Greece, pp. 57-61, 2005.
- [42] D.G. Lainiotis, P. Papapaskeva, G. Kothapalli, K. Plataniotis, Adaptive filter applications to LIDAR: return power and log power estimation, Geoscience and Remote Sensing, IEEE Transactions on, Vol 34, Issue 4, pp. 886-891, 1996.
- [43] V. Petridis, A method for bearings only velocity and position estimation, IEEE Trans. Automatic Control, vol. AC-26, pp. 488-493, April 1981.
- [44] V. Petridis, Bearings only target tracking via partitioning estimation algorithms, in Proc. IFAC Identification and System Parameter Estimation (Washington, DC ), pp. 1659-1664, 1982.
- [45] K. Watanabe, Application of pseudolinear partitioned filter to passive vehicle tracking, Int. J. Systems Science, vol. 15, pp. 959-975, 1984.
- [46] D.G. Lainiotis, S.K. Katsikas and S.D. Likothanassis, Adaptive deconvolution of seismic signals-Performance, computational analysis, parallelism, IEEE Trans. Acoustics, Speech, and Signal Processing, vol. ASSP-36, no. 11, pp. 1715-1734, Nov. 1988.
- [47] D.G. Lainiotis, K.N. Plataniotis, D. Penon, C.J. Charalampous, Neural network application to ship position estimation, OCEANS '93. Engineering in Harmony with Ocean. Proceedings, vol 1, pp. 1384-1389 vol.1, 1993.
- [48] D.G. Lainiotis, P. Papapaskeva, A partitioned adaptive approach to nonlinear channel equalization, Communications, IEEE Transactions on, vol 46, Issue 10, pp. 1325-1336, 1998.
- [49] S.K. Katsikas, S.D. Likothanassis, G.N. Beligiannis, K.G. Berketis, D.A. Fotakis, Genetically determined variable structure multiple model estimation, Signal Processing, IEEE Transactions on, vol 49, Issue 10, pp. 2253-2261, 2001.
- [50] B.D.O. Anderson and J.B. Moore.; Optimal Filtering, Englewood Cliffs, NJ: Prentice Hall, 1979.
- [51] J.M. Mendel, Lessons in Digital Estimation Theory, Englewood Cliffs, NJ: Prentice Hall, 1987.
- [52] R.M. Hawkes and J.B. Moore, Performance of Bayesian parameter estimators for linear signal models, Automatic Control, IEEE Transactions on, vol AC-21, pp. 523-527, 1976.

- [53] D.G. Lainiotis and S.K. Park, Probability of error bounds, IEEE Trans. Systems, Man, Cybernetics, vol. SMC-7, pp. 175-178, Apr. 1971.
- [54] Ασημάκης Λερός, Αυτοπροσαρμοζόμενοι αλγόριθμοι εκτίμησης για παθητική παρακολούθηση ελίσσομένου στόχου, Διδακτορική διατριβή, Πανεπιστήμιο Πατρών, Σεπτέμβριος 1998.
- [55] R.L. Sengbush and D.G. Lainiotis, Simplified parameter quantization procedure for adaptive estimation, IEEE Trans. Automat. Contr., vol AC-14, pp. 424-425, 1969.
- [56] R. Shibata, Asymptotically efficient selection of the order of the model for estimating parameters of a linear process, Ann. Statist. 8, pp. 147-164, 1980.
- [57] S.Sp. Pappas, A.K. Leros, S.K. Katsikas, Joint order and parameter estimation of multivariate autoregressive models using multi-model partitioning theory, Digital Signal Processing, vol. 16, Issue. 6, pp. 782-795, 2006.
- [58] J. McHugh, Intrusion and intrusion detection, Int J Inf Security, vol. 1, Issue. 1, pp. 14-35, 2001.
- [59] W. Lee, S.J Stolfo, A framework for constructing features and models for intrusion detection systems, ACM Trans Inf Systems Security, vol. 3, Issue. 4, pp. 227-61, 2000.
- [60] S. Forrest, S.A Hofmeyr, A. Somayaji, T.A. Longstaff, A sense of self for unix processes, Proceedings of the 1996 IEEE symposium on security and privacy. Silver Spring, MD: IEEE Computer Society, p. 120, 1996.
- [61] H. Debar, M. Becker, D. Siboni, A neural network component for an intrusion detection system, Proceedings of the 1992 IEEE symposium on security and privacy. Silver Spring, MD: IEEE Computer Society, p. 240, 1992.
- [62] A.K Ghosh, A. Schwartzbard, A study in using neural networks for anomaly and misuse detection, Proceedings of the eighth USENIX security symposium, 1999.
- [63] T. Lane, C.E. Brodley, Approaches to online learning and concept drift for user identification in computer security, Proceedings of the fourth international conference on knowledge discovery and data mining, p. 259-63, 1998.
- [64] Y. Liao V.R Vemuri, Use of k-nearest neighbour classifier for intrusion detection, Comput. Security, vol. 21, Issue. 5, pp. 439-48, 2002.
- [65] E. Eskin, A. Arnold, M. Prerau, L. Portnoy, S. Stolfo, A geometric framework for unsupervised anomaly detection: detecting intrusions in unlabeled data, Editors: D. Bar-



bara, S. Jajodia, Applications of data mining in computer security. Dordrecht: Kluwer; 2002.

[66] A. Lazarevic, L. Ertoz, V. Kumar, A. Ozgur, J. Srivastava, A comparative study of anomaly detection schemes in network intrusion detection, Proceedings of the third SIAM international conference on data mining. San Francisco, CA. pp. 25–36, 2003.

[67] E. Eskin, Anomaly detection over noisy data using learned probability distributions, Proceedings 17<sup>th</sup> international conference on machine learning. San Francisco, CA: Morgan Kaufmann, pp. 255–62, 2003.

[68] M.V. Mahoney, P.K. Chan, Learning nonstationary models of normal network traffic for detecting novel attacks, Proceedings of the eighth ACM SIGKDD international conference on knowledge discovery and data mining. New York: ACM Press, pp. 376–85, 2002.

[69] H.S. Javitz, A. Valdes, The nides statistical component description and justification, Technical Report, Computer Science Laboratory, SRI International, Menlo Park, CA, March 1994.

[70] K. Yamanishi, J. Takeuchi, G. Williams, On-line unsupervised outlier detection using finite mixtures with discounting learning algorithms, Data Mining and Knowledge Discovery, pp. 275–300, 2004.

[71] H.S. Teng, K. Chen, S.C. Lu, Adaptive real-time anomaly detection using inductively generated sequential patterns, Proceedings of IEEE symposium on security and privacy. Oakland, CA, pp. 278–84, 1990.

[72] T. Lane, C.E. Brodley, Temporal sequence learning and data reduction for anomaly detection, ACM Trans Inf Systems Security, 2(3), pp. 295–331, 1999.

[73] M. Hossain, S.M. Bridges, A framework for an adaptive intrusion detection system with data mining, Proceedings of the 13th annual Canadian information technology security symposium. Ottawa, Canada, 2001.

[74] V. C. Moussas, M. Daglis and E. Kolega, Network Traffic Mod-elling and Prediction Using Multiplicative Seasonal ARIMA Models, 1st Interna-tional Conference on Experiments/Processes/System Model-ling/Simulations/Optimisation, Athens, 6-9 July, 2005.

[75] Oetiker Tobias, Multi Router Traffic Grapher MRTG tool, Software Package and Manulas, <http://people.ee.ethz.ch/~oetiker/webtools/mrtg/>, last visit: Feb 2005.

- [76] G. Box, G.M. Jenkins and G. Reinsel, Time Series Analysis: Forecasting & Control, 3rd edition, Prentice Hall, 1994.
- [77] C.P. Chen, J.A. Bilmes, MVA Processing of Speech Features, Audio, Speech and Language Processing, *IEEE Transactions on Audio, Speech and Language Processing*, vol 15, Issue 1, pp. 257-270, 2007.
- [78] Sheng, Lu., Ki, Hwan Ju., K.H. Chon, A new algorithm for linear and nonlinear ARMA model parameter estimation using affine geometry [and application to blood flow/pressure data], *Biomedical Engineering, IEEE Transactions on*, vol 48, Issue 10, pp. 1116-1124, 2001.
- [79] M. Kourosh, H.R. Eslami and R. Kahawita, Parameter estimation of an ARMA model for river flow forecasting using goal programming, *Journal of Hydrology*, vol 331, Issues 1-2, pp. 293-299, 2006.
- [80] J. Derk, S. Weber, C. Weber, Extended ARMA models for estimating price developments on day-ahead electricity markets, *Electric Power Systems Research*, vol 77, Issues 5-6, pp. 583-593, 2007.
- [81] A.A. Mobarakeh, F.R. Rofooei, G. Ahmadi, Simulation of earthquake record using time-varying Arma (2,1) model, *Probabilistic Engineering Mechanics*, vol 17, pp. 15-34, 2002.
- [82] V. Papakos, D.S. Fassois, Multichannel Identification of aircraft skeleton structures under unobservable excitation: a vector AR / ARMA framework, *Mechanical Systems and Signal Processing*, vol 17, Issue 6, pp. 1271-1290, 2003.
- [83] H. Akaike, A new look at the statistical model identification,, *IEEE Trans. on Automatic Control* AC-19, pp. 716-723, 1974.
- [84] H. Akaike, Information theory and an extension of the maximum likelihood principle, In Petrov, B. N., Csàki F (Eds), *Proceedings of the second international symposium on information theory*, Akadémia Kiadó, Budapest, pp. 267-281, 1973.
- [85] A. Kaderli, A. Kayhan, Spectral estimation of ARMA processes using ARMA-cepstrum recursion, *IEEE Signal Processing Lett.*, vol 7, pp. 259-261, 2000.
- [86] A. Kizilkaya, and A.H. Kayran, ARMA model parameter estimation based on the equivalent MA approach, *Digital Signal Processing*, vol. 16, Issue 6, pp. 670-681, 2006.

- [87] A. Kizilkaya, and A.H. Kayran, Estimation of 2-D ARMA model parameters by using equivalent AR approach, *Journal of the Franklin Institute*, vol 342, Issue 1, pp. 39-67, 2005.
- [88] G. Kothapalli, S. Lachowicz, K. Eshraghian, A parameter search technique to build an ARMA model, in: *IEEE Proc. 2nd Int. Conf. Knowledge-Based Intelligent Electronic Systems*, Adelaide, Australia, pp. 298-301, 1998.
- [89] S. Li, B.W. Dickinson, Application of the lattice filter to robust estimation of AR and ARMA models, *IEEE Trans. Acoust. Speech Signal Process.*, vol 36, pp. 502-512, 1988.
- [90] M.D. Ortigueira, A three step algorithm for ARMA modeling, *Signal Processing*, vol 15, Issue 1, pp. 23-30, 1988.
- [91] Z. Shufang, L. Renjie, A rapid algorithm for on-line and real-time ARMA modeling, in: *IEEE Proc. 5th Int. Conf. Signal Processing*, Beijing, China, pp. 230-233, 2000.
- [92] G. Beligiannis, L. Skarlas, S. Likothanassis, A generic applied evolutionary hybrid technique, *Signal Processing Magazine, IEEE*, vol 21, Issue 3, pp. 28-38, 2004.
- [93] R. Ariew, Ockham's Razor: A historical and philosophical analysis of Ockhams principle of parsimony, Champaign-Urbana, University of Illinois, 1976.
- [94] M. Stone, Cross-validators choice and assessment of statistical predictions, *J. Royal Statist. Soc., B*, vol. 36, pp. 11-147 (with discussion), 1974.
- [95] A.C. Atkinson, Posterior probabilities for choosing a regression model, *Biometrika*, vol 65, pp. :39-48, 1978.
- [96] S.Sp. Pappas, V.C. Moussas, S.K. Katsikas, Multivariate ARMA Order Estimation via Multi – Model Partition Theory *2nd International Conference on Experiments/Process/System Modeling/Simulation/Optimization*, 2nd IC-EpsMsO, Athens, 4-7 July, © IC-EpsMsO, 2007.
- [97] PPC S.A. Annual electrical energy's statistical and economical data. Athens: Hellenic Public Power Corporation S.A., 2006.
- [98] Yang M, Yu X. China's rural electricity market-a quantitative analysis, *Energy*, vol. 29, pp. 961-977, 2004.
- [99] K. Padmakumari, K.P. Mohandas, S. Thiruvengadam, Long-term distribution forecasting using neuro-fuzzy computations. *Electric Power Energy Systems*, 21, pp. 315-322, 1999.

- [100] T. Haida, S. Muto, Regression based peak load forecasting using a transformation technique. *IEEE Trans on Power Systems*, 9(4), pp. 1788-1794, 1994.
- [101] J. Contreras, R. Espinola, F.J. Nogales, A.J. Conejo, ARIMA models to predict next-day electricity prices. *IEEE Trans on Power Systems*, 18(3), pp. 1014-1020, 2003.
- [102] M. Zhou, Z. Yan, Y. Ni and G. Li, 2004, An ARIMA approach to forecasting electricity price with accuracy improvement by predicted errors. *IEEE Power Engineering Society General Meeting*, Vol 1, pp. 233-238, 2004.
- [103] J. Lu, D. Niu and Z. Jia, A study of short-term load forecasting based on ARIMA-ANN. *Int. Conf. on Machine Learning and Cybernetics*, Vol 5, pp. 3183-3187, 2004.
- [104] V S Ediger and S. Akar, ARIMA forecasting of primary energy demand by fuel in Turkey. *Energy Policy*, 35 (3), pp. 1701-1708, 2007.
- [105] F.J. Nogales, J. Contreras, A.J. Conejo, R. Espinola, Forecasting next-day electricity prices by time series models. *IEEE Trans on Power Systems*, 17(2), pp. 342–348, 2002.
- [106] R. Weron, B. Kozłowska, J. Nowicka-Zagrajek, Modeling electricity loads in California: a continuous-time approach. *Physica A: Statistical Mechanics and its Applications*, 299(1-2), pp. 344-350, 2001.
- [107] J. Nowicka-Zagrajek, R. Weron, Modeling electricity loads in California: ARMA models with hyperbolic noise. *Signal Processing*, vol. 82, Issue. 12, pp. 1903-1915, 2002.
- [108] Z. Mohamed, P. Bodger, Forecasting electricity consumption in New Zealand using economic and demographic variables. *Energy*, 30, pp. 1833-1843, 2005.
- [109] H.K. Ozturk H. Ceylan, O.E. Canyurt, A. Hepbasli, Electricity estimation using genetic algorithm approach: a case study of Turkey. *Energy*, 30, pp. 1003-1012, 2005.
- [110] B. Kermanshahi, H. Iwamiya, Up to the year 2020 load forecasting using neural nets. *Electric Power Energy Systems*, 17, pp. 789-797, 2002.
- [111] H.C. Wu, C.N. Lu, A data mining approach for spatial modeling in small area load forecast. *IEEE Trans on Power Systems*, 17, pp. 516-521, 2002.
- [112] Λάμπρος Οικονόμου : Ανάπτυξη Μεθοδολογιών για τον Υπολογισμό της Κεραυνικής Συμπεριφοράς και τη Σχεδίαση Γραμμών Μεταφοράς Υψηλής Τάσης, Διδακτορική διατριβή, Εθνικό Μετσόβιο Πολυτεχνείο, Αθήνα, Μάιος 2006.

- [113] L. Ekonomou, P. Liatsis, I.F. Gonos, I.A. Stathopoulos, Artificial Neural Network based Software Tool for Calculating the Lightning Performance of High Voltage Transmission Lines, IEE Proceedings Science, Measurement and Technology, Vol. 153, No. 5, pp. 188-193, September 2006.
- [114] L. Ekonomou, I.F. Gonos, D.P. Iracleous, I.A. Stathopoulos, Application of Artificial Neural Network Methods for the Lightning Performance Evaluation of Hellenic High Voltage Transmission Lines, International Journal of Electrical Power Systems Research, Vol. 77, No. 1, pp. 55-63, January 2007.
- [115] <http://www.im.pwr.wroc.pl/~rweron/MFE.html>
- [116] G.M. Ljung, G.E.P. Box, On a measure of lack of fit in time series models, Biometrika 65, pp. 297-303, 1978.
- [117] <http://www.spatial-econometrics.com/>
- [118] S. J. Huang, K. R. Shih, Short-term load forecasting via ARMA model identification including non-Gaussian process, considerations, IEEE Transactions on Power Systems, Vol 18 (2), pp. 673-679, 2003.
- [119] W. Ruan, R.D. Southey, S. Fortin, F.P. Dawalibi, Effective Sounding Depths for HVDC Grounding Electrode Design: Wenner versus Schlumberger Methods, Transmission and Distribution Conference and Exhibition: Asia and Pacific, IEEE/PES, 2005
- [120] J.K. Choi, Y.H. Ahn, J.W. Woo, G.J. Jung, B.S. Han and K.C. Kim, Evaluation of grounding performance of energized substation by ground current measurement, Electric Power Systems Research, Volume 77, Issue 11, pp. 1490-1494, September 2007
- [121] M.A. Salam, S.M. Al-Alawi and A.A. Maqrash, An artificial neural networks approach to model and predict the relationship between the grounding resistance and length of buried electrode in the soil, Journal of Electrostatics, Volume 64, Issue 5, pp. 338-342, May 2006.
- [122] E. Mombello, O. Trad, J.Rivera and A. Andreoni, Two-layer soil model for power station grounding system calculation considering multilayer soil stratification, Electric Power Systems Research, Volume 37, Issue 1, pp. 67-78, April 1996.
- [123] I.F. Gonos, L. Ekonomou, F.V. Topalis and I.A. Stathopoulos, Probability of back-flashover in transmission lines due to lightning strokes using Monte-Carlo simulation, International Journal of Electrical Power & Energy Systems, Volume 25, Issue 2, pp. 107-111, February 2003.

- [124] I.F. Gonos, A.X. Moronis, I.A. Stathopoulos, Variation of soil resistivity and ground resistance during the year, 28th International Conference on Lightning Protection (ICLP 2006), Kanazawa, Japan, pp. 740-744, 2006.
- [125] P.M.T. Broersen, Automatic Autocorrelation and Spectral Analysis, 1st ed., Springer, 2006.
- [126] P.M.T. Broersen, ARMAseI for identification of univariate measurement data, Proceedings of the IEEE Instrumentation and Measurement Technology Conference (IMTC 2006), pp. 107-112, 2006.
- [127] P.M.T. Broersen, S. de Waele, Automatic identification of time series models from long autoregressive models. IEEE Transactions on Instrumentation and Measurement, 54(5), pp. 1862-1868, 2005.
- [128] P.M.T. Broersen, S. de Waele, Finite sample properties of ARMA order selection. IEEE Transactions on Instrumentation and Measurement, 53(3), pp. 645-651, 2004.
- [129] <http://www.mathworks.com/matlabcentral/fileexchange/loadFile.do?objectId=1330&objectType=FILE>
- [130] B.L. Kermanshahi, H. Iwamiya, Up to year 2020 load forecasting using neural nets, International Journal of Electrical Power and Energy Systems, Volume 24, Number 9, pp. 789-797, November 2002.
- [131] S.D. Likothanassis, E.N. Demiris, and D.G. Carelis, A Real-Time ARMA Model Structure Identification Method, in Proc. Int. Conf. Digital Signal Processing, vol. 2. Univ. of Patras, Greece, pp. 915-918, 1997.
- [132] Hellenic Ministry of Economy and Finance, [www.mnec.gr](http://www.mnec.gr)
- [133] General Secretariat of National Statistical Service of Greece, <http://www.statistics.gr/>
- [134] Hellenic Regulatory Authority for Energy, [www.rae.gr](http://www.rae.gr)
- [135] Data supplied from the National Meteorological Authority of Hellas, 2006.
- [136] R. Lippmann, An introduction to computing with neural nets, IEEE ASSP Magazine, vol. 4, no. 2, pp. 4-22, 1987.