

# ΜΕΘΟΔΟΙ ΥΠΟΛΟΓΙΣΤΙΚΗΣ ΝΟΗΜΟΣΥΝΗΣ ΓΙΑ ΤΗΝ ΠΡΟΒΛΕΨΗ ΧΡΟΝΟΛΟΓΙΚΩΝ ΣΕΙΡΩΝ

Ν. Γ. Παυλίδης<sup>1</sup>, Δ. Κ. Τασουλής<sup>2</sup>, Β. Π. Πλαγιανάκος<sup>3</sup> και  
Μ. Ν. Βραχάτης<sup>4</sup>

Εργαστήριο Υπολογιστικής Νοημοσύνης (C.I.Lab), Τμήμα Μαθηματικών,  
Κέντρο Έρευνας Τεχνητής Νοημοσύνης Πανεπιστημίου Πατρών (UPAIRC),  
Πανεπιστήμιο Πατρών.

## Περίληψη

*Περιγράφεται μια μεθοδολογία για τη μοντελοποίηση και πρόβλεψη χρονολογικών σειρών η οποία αξιοποιεί αλγορίθμους μη-επιβλεπόμενης ομαδοποίησης και τεχνητά νευρωνικά δίκτυα εμπρόσθιας τροφοδότησης. Πιο συγκεκριμένα, ένας αλγόριθμος ομαδοποίησης διαχωρίζει το σύνολο εισόδου σε ομάδες και στη συνέχεια, για κάθε ομάδα εκπαιδεύεται ένα ξεχωριστό τεχνητό νευρωνικό δίκτυο αξιοποιώντας μόνο τα πρότυπα της συγκεκριμένης ομάδας. Η προτεινόμενη μεθοδολογία στοχεύει στην αντιμετώπιση του θορύβου και της μη-στασιμότητας, που εμφανίζονται σε πληθώρα χρονολογικών σειρών που προκύπτουν από προβλήματα του πραγματικού κόσμου.*

## 1. Εισαγωγή

Η Υπολογιστική Νοημοσύνη αποτελεί κλάδο της Τεχνητής Νοημοσύνης και πραγματεύεται την ανάπτυξη μεθοδολογιών στις οποίες η γνώση αναπαρίσταται μη-συμβολικά και οι οποίες επιδεικνύουν χαρακτηριστικά τα οποία αποδίδονται στην ευφυΐα. Σε αντίθεση με την παραδοσιακή τεχνητή νοημοσύνη που υιοθετεί μια top – down προσέγγιση για την επίλυση ενός προβλήματος (δηλαδή, πρώτα αναλύεται η δομή ενός προβλήματος και στη συνέχεια κατασκευάζεται ένα ευφυές σύστημα) η υπολογιστική νοημοσύνη υιοθετεί μια bottom – up προσέγγιση στην οποία η δομή του προβλήματος αναδύεται αντί να επιβάλλεται εκ των προτέρων. Οι μέθοδοι υπολογιστικής νοημοσύνης έχουν την ικανότητα μάθησης και αντιμετώπισης νέων καταστάσεων, έτσι ώστε το σύστημα να παρουσιάζει κάποια χαρακτηριστικά της λογικής όπως η γενίκευση, η ανακάλυψη, η συσχέτιση και η αφαίρεση [3]. Στα πλαίσια της υπολογιστικής νοημοσύνης συγκαταλέγονται τα τεχνητά νευρωνικά δίκτυα, τα ασαφή συστήματα και ο εξελικτικός υπολογισμός.

Ένα κεντρικό επιστημονικό πρόβλημα είναι αυτό της πρόβλεψης, το οποίο συνοψίζεται στην ερώτηση: *Δεδομένου του παρελθόντος, πώς μπορούμε να προβλέψουμε το μέλλον;* [4]. Η τυπική προσέγγιση είναι η κατασκευή ενός θεωρητικού μοντέλου και η εκτίμηση των παραμέτρων του από τα διαθέσιμα δεδομένα. Σε πολλές εφαρμογές

<sup>1</sup> Τηλ: 2610 997348, fax: 2610 992965, e-mail: npav@math.upatras.gr

<sup>2</sup> Τηλ: 2610 997348, fax: 2610 992965, e-mail: dtas@math.upatras.gr

<sup>3</sup> Τηλ: 2610 997381, fax: 2610 992965, e-mail: vpp@math.upatras.gr

<sup>4</sup> Τηλ: 2610 997374, fax: 2610 992965, e-mail: vrahatis@math.upatras.gr

ωστόσο αυτή η προσέγγιση δεν είναι εφικτή λόγω της έλλειψης ενός θεωρητικού πλαισίου που να περιγράφει ικανοποιητικά την συμπεριφορά του συστήματος. Μια διακριτή χρονολογική σειρά αποτελείται από ένα σύνολο παρατηρήσεων μιας μεταβλητής,  $x(t)$ , διατεταγμένες ως προς το χρόνο,  $x_1, x_2, \dots, x_N$ , όπου  $N$  το μέγεθος της σειράς. Η πρόβλεψη χρονολογικών σειρών αποτελεί ενσωμάτωση του προβλήματος της προσέγγισης συναρτήσεων [11]. Δύο από τα κυριότερα προβλήματα στην ανάλυση χρονολογικών σειρών είναι η μη-στασιμότητα και η παρουσία θορύβου [16]. Η μη-στασιμότητα αναφέρεται στην μεταβολή των στατιστικών ιδιοτήτων της διαδικασίας που δημιουργεί τα δεδομένα. Αποτέλεσμα της μη-στασιμότητας είναι η σταδιακή μεταβολή της εξάρτησης μεταξύ των δεδομένων εισόδου και της επιθυμητής εξόδου του προβλεπτικού συστήματος. Με τον όρο θόρυβος, αναφερόμαστε στην ελλιπή πληροφορία για την προηγούμενη συμπεριφορά του υπό μελέτη συστήματος. Ο θόρυβος συχνά προκαλεί την υπερπροσαρμογή (overfitting) στα δεδομένα με τα οποία εκτιμήθηκαν οι παράμετροι του μοντέλου. Το φαινόμενο της υπερπροσαρμογής στα δεδομένα περιορίζει την προβλεπτική ικανότητα οποιουδήποτε μοντέλου όταν αυτό εφαρμόζεται σε νέα δεδομένα.

## 2. Μεθοδολογία

Οι κλασικές μέθοδοι για την πρόβλεψη χρονολογικών σειρών βασίζονται σε μοντέλα καθολικής προσέγγισης (global approximation), αξιοποιώντας τεχνικές όπως η γραμμική παλινδρόμηση, η προσέγγιση με πολυώνυμα, και τα τεχνητά νευρωνικά δίκτυα. Ένας από τους κυριότερους περιορισμούς των καθολικών μοντέλων για την πρόβλεψη χρονολογικών σειρών είναι ότι υποθέτουν την στασιμότητα. Οι Farmer και Sidorowich [4] πρότειναν τη χρήση *τοπικών προβλεπτικών μοντέλων* (local approximators) για την πρόβλεψη χασοτικών χρονολογικών σειρών. Συνοπτικά, για την πρόβλεψη της επόμενης τιμής,  $x(t+1)$ , αρχικά εντοπίζονται οι  $k$  κοντινότεροι γείτονες του διανύσματος του ανακατασκευασμένου χώρου φάσεων,  $\mathbf{x}(\mathbf{t}) = [x(t), x(t-1), \dots, x(t-d)]$ , δηλαδή τα  $k$  διανύσματα  $\mathbf{x}(\mathbf{t}')$ , όπου ( $\mathbf{t}' < \mathbf{t}$ ), που ελαχιστοποιούν την Ευκλείδεια απόσταση  $\|\mathbf{x}(\mathbf{t}) - \mathbf{x}(\mathbf{t}')\|$ . Ένα τοπικό, γραμμικό, μοντέλο, οι παράμετροι του οποίου υπολογίζονται από τα  $k$  διανύσματα  $\mathbf{x}(\mathbf{t}')$ , χρησιμοποιείται για την πρόβλεψη της επόμενης τιμής,  $x(t+1)$ . Η μέθοδος αυτή είναι πιο γενική από την καθολική προσέγγιση αφού απαιτεί την ικανοποίηση λιγότερων στατιστικών και γεωμετρικών υποθέσεων για τα δεδομένα. Στη βιβλιογραφία έχουν προταθεί μεθοδολογίες που αξιοποιούν τοπικές προσεγγίσεις για την πρόβλεψη χρονολογικών σειρών που προκύπτουν από προβλήματα του πραγματικού κόσμου [2,9,10,11,14,16]. Κοινό στοιχείο σε όλες αυτές τις μεθοδολογίες είναι ο συνδυασμός μιας τεχνικής για τον διαχωρισμό του συνόλου εισόδων σε υποσύνολα με ένα τοπικό προσεγγιστικό μοντέλο. Η προτεινόμενη μεθοδολογία διαχωρίζει το σύνολο εισόδων με τη χρήση ενός αλγορίθμου μη-επιβλεπόμενης ομαδοποίησης, ενώ τα τοπικά μοντέλα προσέγγισης είναι τεχνητά νευρωνικά δίκτυα εμπρόσθιας τροφοδότησης (feedforward neural networks) (FNN). Η προτεινόμενη προσέγγιση συνοψίζεται στα ακόλουθα βήματα:

1. Καθορισμός της κατάλληλης διάστασης εμπύθισης των δεδομένων της χρονολογικής σειράς [8].
2. Εντοπισμός των ομάδων που υπάρχουν στο σύνολο εκπαίδευσης με τη χρήση μη-επιβλεπόμενου αλγορίθμου ομαδοποίησης.
3. Για κάθε ομάδα εκπαιδεύεται ένα διαφορετικό FNN, χρησιμοποιώντας σαν σύνολο εκπαίδευσης μόνο τα πρότυπα που ανήκουν στη συγκεκριμένη ομάδα.

4. Για κάθε πρότυπο που ανήκει στο σύνολο ελέγχου:
  - I. Ανάθεση του σε μία από τις ομάδες με κριτήριο την Ευκλείδεια απόστασή του από τα κέντρα των ομάδων.
  - II. Χρήση του αντίστοιχου FNN για την πρόβλεψη της επόμενης τιμής.

## **2.1. Μη-Επιβλεπόμενοι Αλγόριθμοι Ομαδοποίησης**

Ένα κρίσιμο θέμα στη διαδικασία ομαδοποίησης είναι ο καθορισμός του πλήθους των ομάδων που υπάρχουν στο σύνολο των δεδομένων. Τα αποτελέσματα αλγορίθμων που απαιτούν από το χρήστη τον καθορισμό αυτής της παραμέτρου είναι ιδιαίτερα ευαίσθητα στην τιμή αυτής της παραμέτρου αφού η υπερεκτίμηση ή η υποτίμηση του πλήθους των ομάδων οδηγεί στον εντοπισμό ομάδων που περιλαμβάνουν ελάχιστα πρότυπα, ομάδων που έχουν μικρή φυσική σημασία, ή ακόμα και στη συγχώνευση ξεχωριστών ομάδων. Οι αλγόριθμοι ομαδοποίησης που εκτιμούν το πλήθος των ομάδων κατά την εκτέλεση τους αναφέρονται ως μη-επιβλεπόμενοι αλγόριθμοι ομαδοποίησης. Στα πλαίσια της ομαδοποίησης για το διαχωρισμό των προτύπων εισόδου για το σκοπό της πρόβλεψης, το πλήθος των ομάδων είναι εκ των προτέρων άγνωστο και επομένως προτείνουμε τη χρήση μη-επιβλεπόμενων αλγορίθμων. Οι αλγόριθμοι τους οποίους έχουμε εφαρμόσει [10] είναι οι εξής: *μη-επιβλεπόμενος k-windows* (UKW) [15,18], *Growing Neural Gas* (GNG) [5], και ο *Density Based Spatial Clustering of Applications with Noise* (DBSCAN) [13].

### **2.1.1. Μη-Επιβλεπόμενος k – windows (UKW)**

Ο UKW αξιοποιεί παράθυρα για τον εντοπισμό των ομάδων σε ένα σύνολο δεδομένων. Αρχικά ο αλγόριθμος αρχικοποιεί ένα πλήθος παραθύρων και στη συνέχεια μετακινεί και μεγεθύνει κάθε παράθυρο ώστε αυτό να εγκλωβίσει τα πρότυπα που ανήκουν σε μία ομάδα. Οι διαδικασίες της μετακίνησης και της μεγέθυνσης καθοδηγούνται από το πλήθος των σημείων που περικλείονται στο παράθυρο, και τερματίζονται όταν η περεταίρω εφαρμογή τους παύει να αυξάνει σημαντικά το πλήθος αυτών των σημείων. Στο τελικό στάδιο ο αλγόριθμος εξετάζει τα παράθυρα που εγκλωβίζουν κοινά σημεία για συγχώνευση. Η απόφαση για τη συγχώνευση δύο παραθύρων βασίζεται στο πλήθος των κοινών τους σημείων. Η λεπτομερής περιγραφή του αλγορίθμου, καθώς και πειραματικά αποτελέσματα παρουσιάζονται στις εργασίες [15,18].

### **2.1.2. Growing Neural Gas (GNG)**

Ο GNG [5] μπορεί να περιγραφεί σαν ένα γράφημα που αποτελείται από  $m$  κόμβους. Κάθε κόμβος χαρακτηρίζεται από ένα διάνυσμα βαρών που καθορίζει τη θέση του στο χώρο και ένα σύνολο ακμών που τον συνδέει με τους γειτονικούς του κόμβους. Ο GNG αρχικοποιείται με δύο κόμβους που συνδέονται με μια ακμή. Με την παρουσίαση του κάθε προτύπου από το σύνολο δεδομένων εντοπίζεται ο πλησιέστερος σε αυτό κόμβος (κόμβος νικητής) και ανανεώνεται η θέση και το σύνολο ακμών του κόμβου νικητή και των τοπολογικών του γειτόνων. Με αυτό τον τρόπο εντοπίζονται οι μη-ενεργοί κόμβοι και ακμές και καθορίζονται οι θέσεις στις οποίες θα εισαχθούν οι νέοι κόμβοι. Ο αλγόριθμος τερματίζει όταν φτάσει το προκαθορισμένο μέγιστο αριθμό κόμβων.

### **2.1.3. Density Based Spatial Clustering of Applications with Noise (DBSCAN)**

Ο αλγόριθμος DBSCAN [13] βασίζεται στην ιδέα ότι για κάθε σημείο στο εσωτερικό μιας ομάδας πρέπει να υπάρχουν τουλάχιστον  $Minpts$  σημεία σε μια ακτίνα  $Eps$  ( $Eps$

γειτονιά) γύρω από αυτό. Τα σημεία που ανήκουν στα όρια μιας ομάδας περιέχονται σε *Eps* γειτονιές σημείων στο εσωτερικό της ομάδας, αλλά υπάρχουν λιγότερα από *Minpts* σημεία στη δική τους *Eps* γειτονιά. Τέλος ένα σημείο το οποίο δεν είναι ούτε στο εσωτερικό ούτε στο όριο κάποιας ομάδας, θεωρείται θόρυβος. Ο DBSCAN επομένως αναγνωρίζει ομάδες σημείων που ενώνονται από *Eps* γειτονιές με τουλάχιστον *Minpts* σημεία.

## 2.2. Τεχνητά Νευρωνικά Δίκτυα Εμπρόσθιας Τροφοδότησης (FNN)

Τα FNN είναι παράλληλα υπολογιστικά μοντέλα που αποτελούνται από πυκνά διασυνδεδεμένες, απλές και προσαρμοστικές υπολογιστικές μονάδες. Τα FNN χαρακτηρίζονται από μια τάση να συγκεντρώνουν εμπειρική γνώση και να την κάνουν προσπελάσιμη για χρήση. Τα FNN προσομοιώνουν τον ανθρώπινο εγκέφαλο σε δύο θεμελιώδης πλευρές. Καταρχήν, το δίκτυο αποκτά γνώση για το περιβάλλον μέσα από μια διαδικασία μάθησης, και κατά δεύτερο, η γνώση του δικτύου αποθηκεύεται στις διασυνδέσεις μεταξύ των νευρώνων που το αποτελούν [6]. Η υπολογιστική ισχύς των FNNs πηγάζει από την ικανότητα τους να προσαρμόζονται σε ένα σύνολο εκπαίδευσης. Σύμφωνα με το “universal approximation theorem” [17], ένα FNN που αποτελείται από νευρώνες με μη-γραμμική συνάρτηση ενεργοποίησης, οργανωμένους σε ένα μόνο κρυφό επίπεδο, μπορεί να προσεγγίσει μια αυθαίρετη συνεχή συνάρτηση. Αν το FNN δέχεται ως είσοδο μια σειρά από  $n$  προηγούμενες τιμές και στόχος είναι η πρόβλεψη της επόμενης τιμής, τότε το “universal myopic mapping theorem” [12], εξασφαλίζει ότι κάθε “shift invariant” χάρτης μπορεί να προσεγγιστεί αυθαίρετα καλά από μια δομή που αποτελείται από μια τράπεζα γραμμικών φίλτρων που τροφοδοτεί ένα στατικό FNN. Αυτός ο τύπος FNN ονομάζεται “Focused Time-Lagged Feedforward Networks” και έχει χρησιμοποιηθεί ευρέως στη βιβλιογραφία για την πρόβλεψη χρονολογικών σειρών. Σε αυτά τα πλαίσια, ένα σύνολο εκπαίδευσης  $T$  είναι ένα σύνολο από  $P$  πρότυπα που ορίζεται ως:

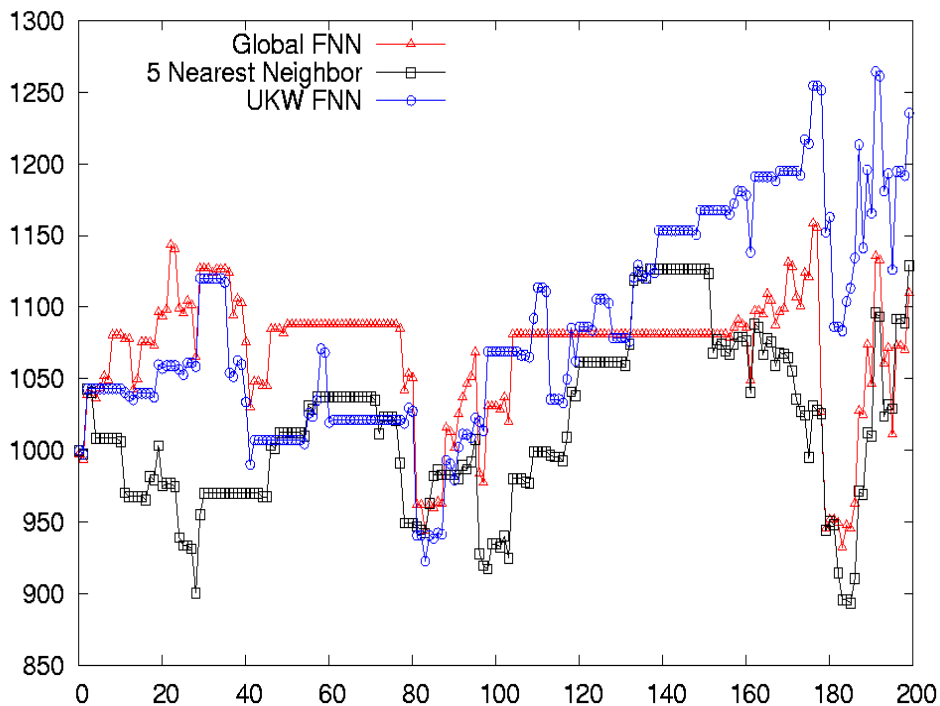
$$T = \{ (\mathbf{x}_k, d_k) / \mathbf{x}_k = (x_k, \dots, x_{k-n+1}), d_k = x_{k+1}, k = 1, \dots, P \}$$

όπου  $\mathbf{x}_k$  αναπαριστά το  $k$ -οστό πρότυπο εκπαίδευσης, και  $d_k$  την επιθυμητή απάντηση που αντιστοιχεί σε αυτό το πρότυπο. Ο στόχος της εκπαίδευσης είναι η ανάθεση τιμών στις ελεύθερες παραμέτρους του δικτύου, δηλαδή τα βάρη  $W$ , ώστε να ελαχιστοποιηθεί η διαφορά μεταξύ των αποκρίσεων του δικτύου και των επιθυμητών αποκρίσεων του δικτύου. Η διαδικασία εκπαίδευσης αρχίζει με την παρουσίαση όλων των προτύπων στο δίκτυο και τον υπολογισμό της συνάρτησης συνολικού σφάλματος  $E$ , η οποία είναι τυπικά το άθροισμα του τετραγωνικού σφάλματος για κάθε πρότυπο εκπαίδευσης. Στην επιβλεπόμενη εκπαίδευση προσαρμόζονται σταδιακά τα βάρη του δικτύου με σκοπό την ελαχιστοποίηση της συνάρτησης σφάλματος. Για την επίτευξη αυτού του στόχου εφαρμόζονται αριθμητικές μέθοδοι βελτιστοποίησης χωρίς περιορισμούς. Η επιβλεπόμενη εκπαίδευση αποτελεί ένα ιδιαίτερα δύσκολο πρόβλημα αφού στις περισσότερες εφαρμογές η διάσταση του χώρου των βαρών είναι μεγάλη και η συνάρτηση σφάλματος χαρακτηρίζεται από πολλά τοπικά ελάχιστα.

## 3. ΑΠΟΤΕΛΕΣΜΑΤΑ ΚΑΙ ΣΥΖΗΤΗΣΗ

Σε αυτή την ενότητα παρουσιάζεται μια εφαρμογή της προτεινόμενης μεθοδολογίας στο χώρο των οικονομικών χρονολογικών σειρών και πιο συγκεκριμένα για την πρόβλεψη της ημερήσιας ισοτιμίας του Ευρώ με το Ιαπωνικό Γιεν [19]. Από τις 1682 διαθέσιμες

παρατηρήσεις που καλύπτουν την περίοδο από το 12/6/1999 ως την 29/6/2005, οι πρώτες 1482 ανατέθηκαν στο σύνολο εκπαίδευσης, ενώ οι τελευταίες 200 παρατηρήσεις χρησιμοποιήθηκαν για την αξιολόγηση της επίδοσης των προβλεπτικών μοντέλων. Ως κριτήριο για την συγκριτική αξιολόγηση των μοντέλων χρησιμοποιήσαμε το κέρδος που επιφέρουν οι συναλλαγές σύμφωνα με τις προβλέψεις του κάθε μοντέλου. Πιο συγκεκριμένα, θεωρούμε ότι την πρώτη μέρα το σύστημα διαθέτει 1000 Ευρώ. Ο απλός κανόνας συναλλαγών που θεωρήσαμε είναι ο ακόλουθος: Αν τη χρονική περίοδο  $t$ , ισχύει ότι  $y_{t+1} > x_t$  (όπου  $y_{t+1}$  η προβλεπόμενη τιμή της επόμενης ημέρας και  $x_t$ , η πραγματική τιμή την παρούσα ημέρα) και το διαθέσιμο ποσό είναι σε Ευρώ, τότε το ποσό μετατρέπεται σε Ιαπωνικά Γιεν. Αντίστροφα, αν ισχύει ότι  $y_{t+1} < x_t$  και το χρηματικό ποσό είναι σε Ιαπωνικά Γιεν τότε μετατρέπεται σε Ευρώ. Σε όλες τις άλλες περιπτώσεις το χρηματικό ποσό δεν αλλάζει συναλλαγματική ισοτιμία. Η τελευταία παρατήρηση της χρονολογικής σειράς αξιοποιείται για τη μετατροπή του διαθέσιμου ποσού σε Ευρώ. Δεδομένου ότι στην πραγματικότητα οι συναλλαγές σε αυτές τις αγορές συνοδεύονται από την καταβολή κάποιου κόστους συμπεριλαμβανόμενου ένα αντιπροσωπευτικό κόστος της τάξης του 0.25% του κεφαλαίου σε όλες τις συναλλαγές [1].



Σχήμα 1 Κερδοφορία των διαφορετικών μεθοδολογιών πρόβλεψης

Χρησιμοποιώντας τη μέθοδο των *εσφαλμένων κοντινότερων γειτόνων* [8] επιλέχθηκε διάσταση εμπύθισης ίση με πέντε. Χρησιμοποιήθηκαν τρία προβλεπτικά μοντέλα: α) ένα FNN το οποίο εκπαιδεύτηκε σε όλο το σύνολο εκπαίδευσης (ολική προσέγγιση), β) η μέθοδος των  $k$ -κοντινότερων γειτόνων (τοπική προσέγγιση), και γ) η προτεινόμενη μεθοδολογία. Μετά από πειραματισμό με την αρχιτεκτονική του δικτύου επιλέχθηκε ένα FNN με αρχιτεκτονική 5 – 5 – 4 – 1 το οποίο εκπαιδεύτηκε μέσω του αλγορίθμου εκπαίδευσης Improved Resilient Propagation (iRPROP) [7], για 200 εποχές. Για τη

μέθοδο των  $k$ -κοντινότερων γειτόνων θεωρήσαμε όλες τις ακέραιες τιμές του  $k$  στο διάστημα  $[1,20]$ . Τα καλύτερα πειραματικά αποτελέσματα επιτεύχθηκαν για  $k=5$ , και είναι αυτά που παρουσιάζονται στο Σχήμα 1. Εφαρμόζοντας τον UKW στο σύνολο εκπαίδευσης, εντοπίστηκαν 21 ομάδες και τα 21 διαφορετικά FNNs με αρχιτεκτονική  $5 - 5 - 4 - 1$  εκπαιδεύτηκαν με τον αλγόριθμο iRPROP για 100 εποχές. Όπως παρουσιάζεται και στο Σχήμα 1, στο τέλος της περιόδου αξιολόγησης το σύστημα συναλλαγών που βασίζεται στο FNN (Global FNN) επιτυγχάνει ένα συνολικό κέρδος 109.57 Ευρώ που αντιστοιχεί σε περίπου 10.1%. Η μέθοδος των κοντινότερων γειτόνων (5 Nearest Neighbors) επιτυγχάνει καλύτερη απόδοση με συνολικό κέρδος 129.16 Ευρώ, 12.9%. Το μέγιστο κέρδος επιτυγχάνεται από την προτεινόμενη μεθοδολογία (UKW FNN) η οποία καταλήγει με κέρδος 235.54 Ευρώ και απόδοση 23.55%.

## Βιβλιογραφία

1. Allen, F. and R. Karjalainen, "Using genetic algorithms to find technical trading rules", *Journal of Financial Economics*, Vol. 51, pp. 245-271, 1999.
2. Cao, L., "Support vector machines experts for time series forecasting", *Neurocomputing*, Vol. 51, pp. 321-329, 2003.
3. Eberhart, R.C., P. Simpson and R. Dobbins, "Computational intelligence PC tools", Academic Press, Inc, Boston, MA, USA, 1996.
4. Farmer, J.D. and J.J. Sidorowich, "Predicting chaotic time series", *Physical Review Letters*, Vol. 59, pp. 845-848, 1987.
5. Fritzke, B., "A growing neural gas network learns topologies", in *Advances in Neural Information Processing Systems*, G. Tesauro, D. S. Touretzky and T. K. Leen (eds), MIT Press, Cambridge MA, pp. 625-632, 1995.
6. Haykin, S., "Neural Networks: A Comprehensive Foundation", New York: Macmillan College Publishing Company, 1999.
7. Igel, C. and M. Husken, "Improving the Rprop Learning Algorithm", in *Proceedings of the 2<sup>nd</sup> International ICSC Symposium on Neural Computation (NC 2000)*, pp. 115-121, 2000.
8. Kennel, M.B., R. Brown and H.D. Abarbanel, "Determining embedding dimension for phase-space reconstruction using a geometrical construction", *Physical Review A*, Vol. 45, pp. 3403-3411, 1992.
9. Milidiu, R.L., R.J. Machado and R.P. Renteria, "Time-series forecasting through wavelets transformation and a mixture of expert models", *Neurocomputing*, Vol. 28, pp. 145-156, 1999.
10. Pavlidis, N.G., D.K. Tasoulis, V.P. Plagianakos and M.N. Vrahatis, "Computational intelligence methods for financial time series modelling", *International Journal of Bifurcation and Chaos*, 2006.
11. Principe, J.C., L. Wang and M.A. Motter, "Local dynamic modeling with self-organizing maps and applications to nonlinear system identification and control", *Proceedings of the IEEE*. Vol. 6, 1998.
12. Sandberg, I.W. and L. Xu, "Uniform approximation of multidimensional myopic maps", *IEEE Transactions on Circuits and Systems I: Fundamental Theory and Applications*, Vol. 44, pp. 477-485, 1997.
13. Sander, J., M. Ester, H.-P. Kriegel and X. Xu, "Density-Based Clustering in Spatial Databases: The Algorithm GDBSCAN and its Applications", *Data Mining and Knowledge Discovery*, Vol. 2, pp. 169-194, 1998.

14. Sfetsos, A. and C. Siriopoulos, "Time Series Forecasting with a Hybrid Clustering Scheme and Pattern Recognition", IEEE Transactions on Systems, Man, and Cybernetics Part A: Systems and Humans, Vol. 34, pp. 399-405, 2004.
15. Tasoulis, D.K. and M.N. Vrahatis, "Unsupervised clustering on dynamic databases", Pattern Recognition Letters, Vol. 26, pp. 2116-2127, 2005.
16. Weigend, A.S., M. Mangeas and A.N. Srivastava, "Nonlinear gated experts for time series: Discovering regimes and avoiding overfitting", International Journal of Neural Systems, Vol. 6, pp. 373-399, 1995.
17. White, H., "Connectionist nonparametric regression: Multilayer feedforward networks can learn arbitrary mappings", Neural Networks, Vol. 3, pp. 535-549, 1990.
18. Vrahatis, M.N., B. Boutsinas, P. Alevizos and G. Pavlides, "The new  $k$ -windows algorithm for improving the  $k$ -means clustering algorithm", Journal of Complexity, Vol. 18, pp. 375-391, 2002.
19. Pavlidis, N.G., D.K. Tasoulis, V.P. Plagianakos, C. Siriopoulos and M.N. Vrahatis, "Computational intelligence methods for financial forecasting", in Proceedings of the International Conference of Computational Methods in Sciences and Engineering (ICCMSE 2005), Vol. 4, pp. 1416-1419, 2005.

#### Abstract:

In this paper we describe a time series forecasting methodology that relies on unsupervised clustering and feedforward neural networks. An unsupervised clustering algorithm partitions the input set into clusters, and subsequently, for each identified cluster a feedforward neural network is trained only on the patterns from the cluster. The methodology aims at handling noise and nonstationarity which are commonly encountered in real world time series.