



ΠΟΛΥΤΕΧΝΕΙΟ ΚΡΗΤΗΣ
TECHNICAL UNIVERSITY OF CRETE

ΤΜΗΜΑ ΜΗΧΑΝΙΚΩΝ ΠΑΡΑΓΩΓΗΣ ΚΑΙ ΔΙΟΙΚΗΣΗΣ

Διπλωματική Εργασία

Τίτλος

Νευροασαφές σύστημα πρόβλεψης των τιμών της Ενέργειας

Επιβλέπων Καθηγητής : Ατσαλάκης Γεώργιος

Φοιτητής : Κατσούλης Στυλιανός

Χανιά 2023

Ευχαριστίες

Η παρούσα εργασία εκπονήθηκε στα πλαίσια του προπτυχιακού κύκλου σπουδών, στο τμήμα Μηχανικών Παραγωγής και Διοίκησης στο Πολυτεχνείο Κρήτης. Αρχικά θα ήθελα να ευχαριστήσω τον καθηγητή και επιβλέποντα στην διπλωματική μου εργασία, κύριο Ατσαλάκη Γεώργιο για την υποστήριξη και την καθοδήγηση του κατά την εκπόνηση της διπλωματικής μου εργασίας. Επίσης θα ήθελα να ευχαριστήσω την οικογένεια μου και τους φίλους μου για την υποστήριξη τους σε κάθε μου απόφαση.

Περίληψη

Το ξέσπασμα της πανδημίας του ιού Covid -19 καθώς και ο πόλεμος στην ανατολική Ευρώπη είναι δύο μόνο παραδείγματα που επηρέασαν καθοριστικά την οικονομία και ιδιαίτερα τον κλάδο της ενέργειας, τόσο σε παγκόσμιο όσο και σε εγχώριο επίπεδο, τα τελευταία χρόνια. Η αβεβαιότητα που δημιουργήθηκε για τα επίπεδα της τιμής της ενέργειας φανέρωσε την αναγκαιότητα που υπάρχει στην παγκόσμια αγορά για αξιόπιστα μοντέλα πρόβλεψης της τιμής αυτής. Η δημιουργία τέτοιων μοντέλων δεν καθίσταται εύκολη καθώς υπάρχει ένας μεγάλος αριθμός εξωτερικών παραγόντων που επηρεάζουν την μεταβολή της τιμής της ενέργειας. Η συγκεκριμένη εργασία παρουσιάζει ένα μοντέλο πρόβλεψης που έχει ως βάση τεχνικές ασαφούς λογικής, και πιο συγκεκριμένα το μοντέλο ANFIS. Η πρόβλεψη γίνεται για τρεις πηγές ενέργειας, που αυτές είναι, το αργό πετρέλαιο, ο άνθρακας και το φυσικό αέριο. Συγκεκριμένα, λαμβάνεται ως βασικό κριτήριο για την δημιουργία κανόνων ασαφούς λογικής οι ημερήσιες τιμές κλεισίματος της κάθε πηγής. Τέλος τα αποτελέσματα του μοντέλου, συγκρίνονται με τα αποτελέσματα ενός μοντέλου AR και ενός μοντέλου ARMA για την αξιολόγηση της αξιοπιστίας του προτεινόμενου μοντέλου.

Abstract

The outbreak of the Covid -19 virus as well as the war in Eastern Europe are just two examples that have decisively affected the economy and especially the energy sector, both globally and domestically, in recent years. The uncertainty created for energy price levels revealed the necessity in the global market for reliable prediction models. The creation of such models is not an easy task as there are many external factors affecting the energy price. This paper presents a prediction model based on fuzzy logic techniques, and more specifically the ANFIS model. The proposed model is used on three energy sources. These are, crude oil, coal and natural gas. In particular, the daily closing spot prices of each source are taken as a basic criterion for the creation of fuzzy logic rules. Finally, the results of the model are compared with the results of an AR and an ARMA model to evaluate the reliability of the proposed model.

Περιεχόμενα

Ευχαριστίες	2
Περίληψη.....	3
Abstract	3
1.Εισαγωγή.....	6
2.Βιβλιογραφική Αναφορά.....	7
3.Θεωρητική Προσέγγιση.....	30
3.1 Ασαφής Λογική.....	30
3.1.1 Εισαγωγή	30
3.1.2 Ασαφή Σύνολα.....	30
3.1.3 Συναρτήσεις Συμμετοχής	31
3.1.4 Ασαφή σύνολα – ιδιότητες και χαρακτηριστικά	35
3.1.5 Λογικές πράξεις μεταξύ ασαφών συνόλων	37
3.1.6 Ασαφείς κανόνες	38
3.1.7 Ασαφή συστήματα	39
3.1.8 Τύποι ασαφών συστημάτων (Fuzzy Inference Systems).....	40
3.1.9 Μέθοδοι αποασαφοποίησης αποτελεσμάτων	42
3.2 Νευρωνικά Δίκτυα.....	44
3.2.1 Ιστορικά στοιχεία	44
3.2.2 Δομή	45
3.2.3 Συναρτήσεις ενεργοποίησης	46
3.2.4 Αρχιτεκτονικές	50
3.2.5 Εκπαίδευση - Μάθηση	53
3.3 ANFIS (Adaptive Neuro-Fuzzy Inference System).....	54
3.3.1 Εισαγωγή	54
3.3.2 Αρχιτεκτονική	56
3.4 Μοντέλα Ανάλυσης Χρονοσειρών (Time Series Models).....	59
3.4.1 Εισαγωγή	59
3.4.2 Μοντέλο AR (AutoRegressive Model)	60
3.4.3 Μοντέλο MA (Moving Average Model).....	60
3.4.4 Μοντέλο ARMA (AutoRegressive Moving Average Model)	61
4.Παρουσίαση και μοντελοποίηση της έρευνας.....	62
4.1 Παρουσίαση δεδομένων	62
4.2 Παρουσίαση μοντέλου ANFIS	63
4.3 Μέτρα σύγκρισης αποτελεσμάτων	64

4.4	Παρουσίαση και σχολιασμός των αποτελεσμάτων	66
5.	Συμπεράσματα	87
6.	Βιβλιογραφία.....	89

1.Εισαγωγή

Οι ενεργειακοί πόροι είναι οι φυσικές πηγές που παρέχουν την ενέργεια που απαιτείται για την τροφοδοσία της καθημερινής μας ζωής. Αυτοί οι πόροι διαχωρίζονται σε δύο βασικούς τύπους: ανανεώσιμους και μη ανανεώσιμους. Οι μη ανανεώσιμες πηγές ενέργειας περιλαμβάνουν ορυκτά καύσιμα όπως ο άνθρακας, το πετρέλαιο και το φυσικό αέριο, τα οποία είναι πεπερασμένοι πόροι που χρειάστηκαν εκατομμύρια χρόνια για να σχηματιστούν. Αυτοί οι πόροι χρησιμοποιούνται εκτενώς για παραγωγή ενέργειας, μεταφορά και βιομηχανικούς σκοπούς, αλλά συνδέονται επίσης με σημαντικές περιβαλλοντικές επιπτώσεις. Από την άλλη, οι ανανεώσιμες πηγές ενέργειας μπορούν να αναπληρωθούν φυσικά και δεν εξαντλούνται με την πάροδο του χρόνου. Αυτές οι πηγές περιλαμβάνουν την ηλιακή, την αιολική, την υδροηλεκτρική, τη γεωθερμία και την ενέργεια από βιομάζα και έχουν τη δυνατότητα να παρέχουν μια βιώσιμη και καθαρή πηγή ενέργειας.

Η πρόβλεψη των τιμών των παραπάνω πηγών είναι ένας σημαντικός τομέας έρευνας στον κλάδο της ενέργειας, καθώς επιτρέπει στις επιχειρήσεις και τις κυβερνήσεις να λαμβάνουν τεκμηριωμένες αποφάσεις σχετικά με την παραγωγή, τη διανομή και την τιμολόγηση της. Οι τιμές της ενέργειας μπορούν να επηρεαστούν από διάφορους παράγοντες, όπως η προσφορά και η ζήτηση, τα γεωπολιτικά γεγονότα, οι καιρικές συνθήκες και οι ρυθμιστικές πολιτικές. Για παράδειγμα η πανδημία του Covid-19 και ο πόλεμος στην Ουκρανία είναι δύο παραδείγματα προσφοράς-ζήτησης και γεωπολιτικών γεγονότων, αντίστοιχα, που επηρέασαν την τιμή της ενέργειας. Επίσης η ακριβής πρόβλεψη των τιμών της ενέργειας μπορεί να βοηθήσει τις εταιρείες να βελτιστοποιήσουν τις στρατηγικές παραγωγής και διανομής τους, να διαχειριστούν τον οικονομικό κίνδυνο και να λάβουν καλύτερες επενδυτικές αποφάσεις. Επιπλέον, οι κυβερνήσεις μπορούν να χρησιμοποιούν προβλέψεις για τις τιμές της ενέργειας για να ενημερώνουν τις αποφάσεις πολιτικής που σχετίζονται με την ενεργειακή ασφάλεια, την περιβαλλοντική βιωσιμότητα και την οικονομική ανάπτυξη. Λαμβάνοντας υπόψη τα παραπάνω είναι σημαντικό να δημιουργούνται μοντέλα πρόβλεψης που να αποσκοπούν στην ακριβή πρόβλεψη των τιμών της ενέργειας. Ιδιαίτερα εν καιρώ αβεβαιότητας, όπου τέτοιες προβλέψεις είναι κρίσιμες για τις αποφάσεις που λαμβάνονται από τις επιχειρήσεις και τις κυβερνήσεις.

2.Βιβλιογραφική Αναφορά

Η πρόβλεψη των τιμών ενέργειας αποτελεί μια ζωτική διαδικασία για την οικονομία και την κοινωνία, καθώς η ενέργεια αποτελεί ένα βασικό συστατικό για τη λειτουργία και την ανάπτυξη του σύγχρονου κόσμου. Η πρόβλεψη των τιμών ενέργειας βοηθάει τις επιχειρήσεις και τους καταναλωτές να λαμβάνουν αποφάσεις σχετικά με τις δαπάνες τους στην ενέργεια, ενώ παράλληλα διευκολύνει τη λειτουργία των αγορών ενέργειας και την ανταγωνιστικότητα του τομέα. Η πρόβλεψη των τιμών ενέργειας βασίζεται στην ανάλυση των δεδομένων που σχετίζονται με την προσφορά και τη ζήτηση της ενέργειας, καθώς και στην ανίχνευση των παραγόντων που επηρεάζουν την αγορά, όπως οι καιρικές συνθήκες, η οικονομική κατάσταση και η πολιτική σταθερότητα. Η ακρίβεια των προβλέψεων των τιμών ενέργειας επηρεάζει την απόδοση της αγοράς, καθώς επιτρέπει στους εμπλεκόμενους παράγοντες να λαμβάνουν σωστές αποφάσεις σχετικά με την παραγωγή, τη διανομή και την κατανάλωση ενέργειας. Επιπλέον, η πρόβλεψη των τιμών ενέργειας είναι σημαντική για την προστασία του περιβάλλοντος, καθώς μπορεί να βοηθήσει στην επιλογή της κατάλληλης πηγής ενέργειας για την παραγωγή ηλεκτρισμού, η οποία έχει την χαμηλότερη επιβάρυνση στο περιβάλλον.

Στην συνέχεια παρουσιάζεται η βιβλιογραφία που αναφέρεται σε μελέτες που σχετίζονται με την πρόβλεψη τιμών ενέργειας. Πιο συγκεκριμένα για τις τιμές του άνθρακα, του αργού πετρελαίου και του φυσικού αερίου. Σε κάθε έρευνα που παρουσιάζεται αναλύονται τα μοντέλα που χρησιμοποιήθηκαν, τα δεδομένα (ορίζοντας πρόβλεψης και είδος δεδομένων), ο τρόπος αξιολόγησης και σύγκρισης των μοντέλων καθώς και τα αποτελέσματα που προκύπτουν.

Using computational intelligence to forecast carbon prices

Η Ευρωπαϊκή Ένωση εισήγαγε το Ευρωπαϊκό Σύστημα Εμπορίου (ETS) ως εργαλείο για την ανάπτυξη και την εφαρμογή διεθνών συνθηκών που σχετίζονται με τις κλιματικές αλλαγές και για τον εντοπισμό των πιο οικονομικά αποδοτικών μεθόδων για τη μείωση των εκπομπών αερίων του θερμοκηπίου, ιδίως του διοξειδίου του άνθρακα (CO₂) όπου είναι το πιο ουσιαστικό. Οι εταιρείες που παράγουν εκπομπές άνθρακα πρέπει να διαχειρίζονται αποτελεσματικά το σχετικό κόστος αγοράζοντας ή πουλώντας futures εκπομπών άνθρακα. Βάση όλων των παραπάνω, η εργασία του George S. Atsalakis (2016) προτείνει ένα μοντέλο για τη διαχείριση του κινδύνου αγοράζοντας και πουλώντας futures εκπομπών άνθρακα με την εφαρμογή τεχνικών που αξιοποιούν την υπολογιστική νοημοσύνη. Τρεις τεχνικές υπολογιστικής νοημοσύνης προτείνονται για την παροχή ακριβών και έγκαιρων προβλέψεων για τις αλλαγές στην τιμή του άνθρακα: ένας νέος υβριδικός νευροασαφής ελεγκτής που σχηματίζει έναν μηχανισμό ανάδρασης κλειστού βρόχου που ονομάζεται PATSOS, ένα τεχνητό νευρωνικό δίκτυο (ANN) και ένα προσαρμοστικό νευροασαφή σύστημα συμπερασμάτων (ANFIS). Τα δεδομένα που χρησιμοποιήθηκαν αφορούν την ημερήσια τιμή των future εκπομπών άνθρακα από την περίοδο 14 Οκτωβρίου 14 2009 έως 29 Οκτωβρίου 2013 και αποτελούνται από 1074 παρατηρήσεις έτσι ώστε να

συνθέσουν ένα χρήσιμο σύνολο δεδομένων χρονοσειρών για την αξιολόγηση των προτεινόμενων τεχνικών. Τα αποτελέσματα που προέκυψαν από το μοντέλο PATSOS συγκρίθηκαν με τα αντίστοιχα αποτελέσματα των μοντέλων ANN (Artificial Neural Network) και ANFIS (Adaptive Neuro-Fuzzy Inference System) με σκοπό την αξιολόγηση της πρόβλεψης του συγκεκριμένου μοντέλου. Η σύγκριση των αποτελεσμάτων έγινε με βάση τριών κριτηρίων, του σφάλματος RMSE (Root Mean Squared Error), του σφάλματος Mean Square Error (MSE) και του σφάλματος Mean Absolute Error (MAE). Οι συγκριτικές μελέτες αποκαλύπτουν ότι το PATSOS είναι η πιο ακριβής και πολλά υποσχόμενη μεθοδολογία για την πρόβλεψη της τιμής του άνθρακα καθώς εμφάνιζε τις μικρότερες τιμές σφαλμάτων σε όλες τις συγκρίσεις. Αξίζει να σημειωθεί ότι αυτή η εργασία καταγράφει μια πρώτη προσπάθεια εφαρμογής ενός υβριδικού νευροασαφούς ελεγκτή για την πρόβλεψη των τιμών του άνθρακα.

Forecasting of carbon emissions prices by the adaptive neuro-fuzzy inference system

Η ανάγκη για ακριβείς προβλέψεις έχει αυξηθεί τα τελευταία χρόνια, αλλά υπάρχει ακόμη περιορισμένη έρευνα σχετικά με τις τάσεις των τιμών των εκπομπών άνθρακα. Αυτή η έρευνα των George S. Atsalakis et.al. (2014) χρησιμοποιεί ένα Adaptive Neuro-Fuzzy Inference System (ANFIS) για την πρόβλεψη των τάσεων των τιμών των εκπομπών άνθρακα. Το ANFIS είναι ένα υβριδικό σύστημα που αποτελείται από νευρωνικά δίκτυα και ασαφή λογική. Χρησιμοποιεί έναν συνδυασμό της μεθόδου των ελαχίστων τετραγώνων (Least Squares) και της μεθόδου back-propagation gradient descent για την εκτίμηση των βέλτιστων παραμέτρων πρόβλεψης τιμής άνθρακα. Αν και το σύστημα είναι γνωστό, έχει τροποποιηθεί για την καλύτερη επεξεργασία των σετ δεδομένων των εκπομπών άνθρακα. Τα δεδομένα που χρησιμοποιήθηκαν αφορούν ημερήσια σετ δεδομένων εκπομπών άνθρακα από την περίοδο 14 Οκτωβρίου 2009 έως την περίοδο 29 Οκτωβρίου 2013, χρησιμοποιώντας 1074 παρατηρήσεις για την εκπαίδευση και την αξιολόγηση του μοντέλου.

Η σύγκριση των αποτελεσμάτων έγινε με βάση πέντε κριτηρίων, του σφάλματος RMSE (Root Mean Squared Error), του σφάλματος Mean Square Error (MSE), του σφάλματος Mean Absolute Error (MAE), του hit rate, όπου είναι το ποσοστό των σωστών προβλέψεων της κατεύθυνσης της τιμής του άνθρακα διά τον αριθμό των προβλέψεων και του Return of Equity, όπου είναι το κέρδος που προκύπτει όταν γίνονται συναλλαγές όπως προτείνει το μοντέλο. Τα αποτελέσματα της προσομοίωσης και των πειραματικών ερευνών που πραγματοποιήθηκαν έδειξαν ότι το μοντέλο είναι κατάλληλο για την πρόβλεψη των τάσεων των τιμών των εκπομπών άνθρακα. Μία περαιτέρω αξιολόγηση όπου πραγματοποιήθηκε συνέκρινε τις αποδόσεις από συναλλαγές, σύμφωνα με το σήμα του προβλεπόμενου συστήματος, με τη στρατηγική buy-and-hold.

Commodities' price trend forecasting by a neuro-fuzzy controller

Αυτή η έρευνα των George S. Atsalakis et.al. (2015) παρουσιάζει μια νέα τεχνική για την πρόβλεψη της τάσης των τιμών (κατεύθυνση) 25 διαφορετικών commodities, που είναι εισηγμένα στις διεθνείς αγορές, χρησιμοποιώντας έναν νευροασαφή ελεγκτή. Το σύστημα πρόβλεψης βασίζεται σε δύο ανεξάρτητα προσαρμοστικά νευρωνικά ασαφή συστήματα συμπερασμάτων (ANFIS) που σχηματίζουν έναν αντίστροφο ελεγκτή για κάθε commodity. Ο ελεγκτής ANFIS ανήκει στον άμεσο έλεγχο και βασίζεται στην αντίστροφη μάθηση, γνωστή και ως γενική μάθηση. Ημερήσια σετ δεδομένων, για την περίοδο 14 Οκτωβρίου 2009 έως 28 Σεπτεμβρίου 2012 για 25 διαφορετικά commodities, χρησιμοποιούνται για την εκμάθηση και την αξιολόγηση του προτεινόμενου συστήματος. Τα commodities όμως που σχετίζονται με την παρούσα πτυχιακή εργασία και των οποίων τα αποτελέσματα θα αναλυθούν παραπάνω είναι τα Brent oil, crude oil, natural gas, heating oil, London gas oil και carbon emissions.

Η σύγκριση των αποτελεσμάτων έγινε με βάση πέντε κριτηρίων, του σφάλματος RMSE (Root Mean Squared Error), του σφάλματος Mean Square Error (MSE), του σφάλματος Mean Absolute Error (MAE), του hit rate, όπου είναι το ποσοστό των σωστών προβλέψεων της κατεύθυνσης της τιμής του άνθρακα διά τον αριθμό των προβλέψεων και του Return of Equity, όπου είναι το κέρδος που προκύπτει όταν γίνονται συναλλαγές όπως προτείνει το μοντέλο. Τα αποτελέσματα της έρευνας δείχνουν ότι το προτεινόμενο μοντέλο κάνει την καλύτερη πρόβλεψη καθώς έχει τις μικρότερες τιμές σφαλμάτων από όλα τα υπόλοιπα μοντέλα στα commodities που αφορούν την ενέργεια.

Neuro-Fuzzy Versus Traditional Models for Forecasting Wind Energy Production

Είναι γνωστό ότι η διαδικασία πρόβλεψης παραγωγής αιολικής ενέργειας είναι πολύ δημοφιλής σε πολλούς ερευνητές που ασχολούνται με τις ΑΠΕ (ανανεώσιμες πηγές ενέργειας). Η έρευνα των Atsalakis G. et.al. (2009) παρουσιάζει μια μέθοδο πρόβλεψης παραγωγής αιολικής ενέργειας, που πραγματοποιήθηκε με τη χρήση προσαρμοστικού νευρωνικού δικτύου με ασαφές σύστημα συμπερασμάτων (ANFIS). Το μοντέλο ελέγχεται με δύο διαφορετικές εισόδους: τιμές με χρονική καθυστέρηση της μέσης ταχύτητας του ανέμου και της μέγιστης ταχύτητας του ανέμου. Η one step ahead τιμή της παραγωγής ενέργειας αντιπροσωπεύει την έξοδο του μοντέλου. Το ANFIS χρησιμοποιεί έναν συνδυασμό της μεθόδου των ελαχίστων τετραγώνων (Least Squares) και της μεθόδου back-propagation gradient descent για την εκτίμηση των βέλτιστων παραμέτρων του μοντέλου. Το μοντέλο εφαρμόζεται σε ένα αιολικό πάρκο στο νησί της Εύβοιας στην Ελλάδα. Τα αποτελέσματα συγκρίνονται με αυτά του Auto-Regressive μοντέλου (AR) και αυτά του Auto-Regressive Moving Average μοντέλου αυτοπαλινδρομικού (ARMA).

Η σύγκριση των αποτελεσμάτων έγινε με βάση τεσσάρων κριτηρίων, του σφάλματος RMSE (Root Mean Squared Error), του σφάλματος Mean Square Error (MSE), του

σφάλματος Mean Absolute Error (MAE) και του Mean Absolute Percentage Error (MAPE). Το ANFIS εμφανίζει μικρότερες τιμές στα σφάλματα από τα υπόλοιπα μοντέλα που συγκρίνεται, άρα παρουσιάζει και καλύτερη πρόβλεψη.

Forecasting the electricity demand using a neuro- fuzzy approach versus traditional methods

Αυτή η έρευνα των Atsalakis G & Ucenic C. (2006) παρουσιάζει ένα νευρο-ασαφές μοντέλο για την επίλυση της μεσοπρόθεσμης πρόβλεψης ηλεκτρικού φορτίου. Το μοντέλο χρησιμοποιεί μια χρονοσειρά μηνιαίων δεδομένων. Η πρόβλεψη φορτίου βασίζεται στο Adaptive Neuro-Fuzzy Inference System (ANFIS). Τα αποτελέσματα συγκρίνονται με αυτά ενός Autoregressive μοντέλου (AR) και ενός Autoregressive Moving Average μοντέλου (ARMA). Η σύγκριση των αποτελεσμάτων έγινε με βάση τεσσάρων κριτηρίων, του σφάλματος RMSE (Root Mean Squared Error), του σφάλματος Mean Square Error (MSE), του σφάλματος Mean Absolute Error (MAE) και του Mean Absolute Percentage Error (MAPE). Το μοντέλο ANFIS έδωσε καλύτερα αποτελέσματα από αυτά των AR και ARMA καθώς είχε τις μικρότερες τιμές σφαλμάτων.

A New Method for Crude Oil Price Forecasting Based on Support Vector Machines

Η έρευνα των Wen Xie et.al. (2006) προτείνει μία εναλλακτική μέθοδο πρόβλεψης της τιμής του αργού πετρελαίου βασισμένη στα Support Vector Machines (SVM). Τα δεδομένα που χρησιμοποιήθηκαν αφορούν την μηνιαία τιμή του West Texas Intermediate (WTI) αργού πετρελαίου από την περίοδο του Ιανουαρίου του 1970 έως τον Δεκέμβριο του 2003 (408 τιμές). Τα αποτελέσματα που προέκυψαν συγκρίθηκαν με τα αντίστοιχα αποτελέσματα των μοντέλων ARIMA (Autoregressive Integrated Moving Average) και BPNN (Back Propagation Neural Network) με σκοπό την αξιολόγηση της πρόβλεψης του συγκεκριμένου μοντέλου. Η σύγκριση των αποτελεσμάτων έγινε με βάση δύο κριτηρίων, του σφάλματος RMSE (Root Mean Squared Error) και του Direction Statistics.

Από το σύνολο των τιμών οι 360 χρησιμοποιήθηκαν για την εκπαίδευση του μοντέλου (training) και οι υπόλοιπες 48 για δοκιμή (test). Τα αποτελέσματα που προέκυψαν δείχνουν ότι το μοντέλο SVM παρουσιάζει το μικρότερο σφάλμα RMSE και την μεγαλύτερη τιμή στο Direction Statistics, δηλαδή κάνει την καλύτερη πρόβλεψη στα συγκεκριμένα δεδομένα. Επομένως η έρευνα καταλήγει ότι τα SVM αποδίδουν αρκετά καλά σε πρόβλεψη χρονοσειρών.

A deep learning ensemble approach for crude oil price forecasting

Η έρευνα των Yang Zhao et.al. (2017) προσεγγίζει την πρόβλεψη της τιμής του αργού πετρελαίου με την χρήση Ensemble Αλγορίθμων. Οι αλγόριθμοι που χρησιμοποιήθηκαν είναι οι Random Walk (RW), Markov Regime Switching (MRS), Support Vector Regression (SVR), Feedforward Neural Network (FNN), Stacked denoising autoencoders (SDAE), καθώς και οι Ensemble αλγόριθμοι των SVR, FNN και SDAE που παρουσιάζονται ως SVR-B, FNN-B, SDAE-B αντίστοιχα. Τα δεδομένα που χρησιμοποιήθηκαν αφορούν το West Texas Intermediate (WTI) αργό πετρέλαιο από την περίοδο του Ιανουαρίου του 1986 έως τον Μάιο του 2016 (365 παρατηρήσεις). Η κάθε παρατήρηση (μία παρατήρηση ανά μήνα) περιλαμβάνει 198 μεταβλητές στις οποίες εμπεριέχονται διάφορες τιμές που σχετίζονται και μπορούν να επηρεάσουν την τιμή του αργού πετρελαίου. Από το σύνολο των παρατηρήσεων το 80% χρησιμοποιήθηκε για την εκπαίδευση των μοντέλων και το υπόλοιπο 20% για την δοκιμή τους. Η σύγκριση των μοντέλων έγινε με την χρήση τριών δεικτών, οι οποίοι είναι ο Directional Accuracy (DA), ο Mean Absolute Percentage Error (MAPE) και ο Root Mean Squared Error (RMSE).

Τα αποτελέσματα της έρευνας δείχνουν ότι κάθε Ensemble μοντέλο αποδίδει καλύτερα από το αντίστοιχο απλό σε όλους τους δείκτες εκτός από το μοντέλο SVR-B όπου αποδίδει χειρότερα από το απλό SVR. Επομένως οι Ensemble αλγόριθμοι των deep learning αλγορίθμων βοηθάνε στην καλύτερη πρόβλεψη. Τέλος τα μοντέλα RW και MRS, βάση των δεικτών, έχουν την χαμηλότερη απόδοση συγκριτικά με τα υπόλοιπα.

Forecasting oil, coal, and natural gas prices in the pre-and post-COVID scenarios: Contextual evidence from India using time series forecasting tools

Η πρόβλεψη της χρηματιστηριακής τιμής θεωρείται ένα κρίσιμο ζήτημα για τον σχεδιασμό μελλοντικών επενδύσεων. Εξάλλου, δεδομένου του γεγονότος ότι η πανδημία COVID-19 έχει επηρεάσει δυσμενώς τις χρηματιστηριακές αγορές παγκοσμίως, ειδικά τα τελευταία δύο χρόνια, οι επενδυτικές αποφάσεις έχουν γίνει πιο απαιτητικές και με μεγαλύτερο ρίσκο. Ως εκ τούτου, η έρευνα των Md Shabbir Alam et.al. (2023) προτείνει ένα πλαίσιο δύο φάσεων για την πρόβλεψη των τιμών του πετρελαίου, του άνθρακα και του φυσικού αερίου στην Ινδία, τόσο για πριν όσο και για μετά τον COVID-19.

Τα μοντέλα που χρησιμοποιήθηκαν είναι τα Autoregressive Integrated Moving Average (ARIMA), Simple Exponential Smoothing (SES) και K-Nearest Neighbor (K-NN). Τα δεδομένα που χρησιμοποιήθηκαν ήταν οι ημερήσιες τιμές κλεισίματος (μόνο εργάσιμες μέρες) του πετρελαίου, του άνθρακα και του φυσικού αερίου στην Ινδία για την περίοδο από τον Ιανουάριο του 2020 έως τον Μάιο του 2022. Τα δεδομένα τροποποιήθηκαν έτσι ώστε να υπολογίζεται η μέση τιμή ανά εβδομάδα για τις παραπάνω τιμές ενέργειας. Έτσι προέκυψαν 57 παρατηρήσεις για πριν και 57 παρατηρήσεις για μετά τον COVID-19. Η αξιολόγηση των μοντέλων έγινε με βάση τριών κριτηρίων. Του Root Mean Squared Error (RMSE), του Mean Absolute Error (MAE) και του Mean Absolute Percentage Error (MAPE).

Από την αξιολόγηση των μοντέλων προέκυψε ότι το μοντέλο ARIMA αποδίδει καλύτερα από τα άλλα δύο μοντέλα καθώς παρουσιάζει μικρότερα σφάλματα για όλες τις τιμές ενέργειας. Επιπλέον παρατηρείται ότι η προγνωστική ακρίβεια του πετρελαίου, του άνθρακα και του φυσικού αερίου στην προ-COVID-19 περίοδο φαίνεται να είναι καλύτερη από ότι στο στάδιο μετά τον COVID-19. Τέλος το μοντέλο ARIMA χρησιμοποιήθηκε για την πρόβλεψη των τιμών τις ενέργειας την περίοδο από τον Ιούνιο του 2022 έως τον Απρίλιο του 2025 προβλέποντας μία αύξηση των τιμών αυτών.

Daily natural gas price forecasting by a weighted hybrid data-driven model

Με τον ρόλο του φυσικού αερίου να αποκτά αυξανόμενη σημασία στη μετάβαση του παγκόσμιου ενεργειακού συστήματος και στην αντιμετώπιση της παγκόσμιας κλιματικής αλλαγής, η ακριβής πρόβλεψη της τιμής του καθίσταται ζωτικής σημασίας. Η συγκεκριμένη έρευνα των Jianliang Wang et.al (2020) παρουσιάζει τρία μοντέλα, το Support Vector Regression (SVR), το Long-Term and Short-Term Memory Network (LSTM) καθώς και μία βελτιωμένη έκδοση του απλού Pattern Sequence Similarity Search (PSS) το IPSS. Επιπλέον συνδυάζονται τα παραπάνω μοντέλα και παρουσιάζεται ένα υβριδικό μοντέλο που τα εμπεριέχει. Τα δεδομένα που χρησιμοποιήθηκαν ήταν η ημερήσια τιμή κλεισίματος του φυσικού αερίου για την περίοδο από 07/01/1997 έως 31/05/2019. Τα δεδομένα που χρησιμοποιήθηκαν για την εκπαίδευση του μοντέλου αφορούσαν την περίοδο από 07/01/1997 έως 31/05/2018 ενώ για την δοκιμή αφορούσε την περίοδο από 01/06/2018 έως 31/05/2019. Από το αρχικό σύνολο των 5385 δεδομένων στο σετ εκπαίδευσης και αφού επεξεργάστηκαν κατάλληλα τα δεδομένα ο αριθμός αυτός υποχώρησε στα 5207. Έπειτα δημιουργήθηκαν τρεις περιπτώσεις για τα δεδομένα αυτά. Μία περίπτωση που περιείχε όλα τα δεδομένα, μία περίπτωση που περιείχε δεδομένα από 01/2002 έως 05/2018 (3970 δεδομένα) και μία περίπτωση που περιείχε δεδομένα από 01/2007 έως 05/2018 (2811 δεδομένα). Η αξιολόγηση έγινε βάση δύο κριτηρίων, του Mean Relative Error (MRE) και του Mean Absolute Percentage Error (MAPE).

Τα αποτελέσματα της έρευνας έδειξαν τα εξής. Αρχικά από τις τρεις περιπτώσεις των σετ εκπαίδευσης φαίνεται ότι το μοντέλο παρουσιάζει τα μικρότερα σφάλματα στην περίπτωση που περιείχε όλα τα δεδομένα. Δηλαδή για περισσότερα δεδομένα εκπαίδευσης το μοντέλο παρουσίαζε πιο ικανοποιητική πρόβλεψη. Έπειτα το υβριδικό μοντέλο συγκρίθηκε με άλλα επτά μοντέλα από τα οποία είχε πιο ικανοποιητική πρόβλεψη καθώς παρουσίαζε τις μικρότερες τιμές σφαλμάτων. Επομένως το μοντέλο αυτό που παρουσιάζει η έρευνα φαίνεται αρκετά ικανό στην πρόβλεψη της τιμής του φυσικού αερίου.

Nonlinearity in forecasting energy commodity prices: Evidence from a focused time-delayed neural network

Ο σκοπός της έρευνας των Ahmed Bouteska et.al. (2023) είναι η δημιουργία ενός μοντέλου πρόβλεψης βασισμένο σε νευρωνικό δίκτυο και πιο συγκεκριμένα το Nonlinear Focused Time-Delayed Neural Network (FTDNN) για την πρόβλεψη των τιμών ενέργειας. Οι τιμές της ενέργειας που χρησιμοποιήθηκαν για την αξιολόγηση του μοντέλου αφορούσαν τις τιμές του αργού πετρελαίου και του φυσικού αερίου. Για το αργό πετρέλαιο χρησιμοποιήθηκαν οι τιμές του West Texas Intermediate (WTI) με 3293 παρατηρήσεις και οι τιμές του Brent με 3311 παρατηρήσεις. Ενώ για το φυσικό αέριο χρησιμοποιήθηκαν οι τιμές του National Balancing Point (NBP) με 3336 παρατηρήσεις και οι τιμές του Henry Hub (HH) με 3289 παρατηρήσεις. Τα δεδομένα αφορούν την περίοδο από τον Σεπτέμβριο του 2007 έως τον Σεπτέμβριο του 2020. Το 70% αυτών των δεδομένων χρησιμοποιήθηκε ως σετ εκπαίδευσης (training set) το 15% ως validation set και το υπόλοιπο 15% ως test set. Για την αξιολόγηση του μοντέλου χρησιμοποιήθηκαν τα εξής κριτήρια. Το Mean Square Error (MSE), το Root Mean Square (RMSE) και το Directional Accuracy (DA). Έπειτα έγινε σύγκριση του μοντέλου αυτού με άλλα τέσσερα μοντέλα και συγκρίθηκε με βάση του RMSE. Τα μοντέλα αυτά ήταν το ARIMA, ένα ANN με ένα κρυφό επίπεδο, ένα ANN με δύο κρυφά επίπεδα και ένα Elman RNN.

Τα αποτελέσματα που προέκυψαν δείχνουν ότι το μοντέλο που παρουσιάζει η έρευνα είναι ικανό να προβλέψει τις συγκεκριμένες τιμές ενέργειας όπως φαίνεται από τα αντίστοιχα κριτήρια. Στην συνέχεια από την σύγκριση των μοντέλων προκύπτει ότι το FTDNN αποδίδει καλύτερα από τα υπόλοιπα μοντέλα καθώς έχει μικρότερη τιμή στο RMSE σε όλες τις μορφές ενέργειας.

Long-term forecast of energy commodities price using machine learning

Η συγκεκριμένη έρευνα των Gabriel Paes Herrera et.al. (2019) έχει σκοπό την σύγκριση παραδοσιακών οικονομετρικών μοντέλων με μεθόδους μηχανικής μάθησης για την πρόβλεψη των τιμών στις βασικές μορφές ενέργειας (αργό πετρέλαιο, άνθρακα και φυσικό αέριο). Για τα παραδοσιακά οικονομετρικά μοντέλα δημιουργήθηκε ένα υβριδικό όπου περιείχε πέντε από αυτά, το Autoregressive Integrated Moving Average (ARIMA), το Error, Trend and Seasonality (ETS), το Seasonal and Trend Decomposition using Loess (STL), το Exponential Smoothing State Space Model with Box-Cox Transformation, ARMA errors, Trend and Seasonal components (TBATS) και το μοντέλο Theta. Ενώ για τα μοντέλα μηχανικής μάθησης χρησιμοποιήθηκε ένα Νευρωνικό Δίκτυο (ANN) και μοντέλο Random Forest (RF). Τα δεδομένα που χρησιμοποιήθηκαν αφορούν τις τιμές του WTI, του Brent και του Dubai Fateh αργού πετρελαίου, του άνθρακα (AU) καθώς και του φυσικού αερίου για ΗΠΑ και Ρωσία. Για το αργό πετρέλαιο και τον άνθρακα τα δεδομένα αφορούν την περίοδο από τον Ιανουάριο του 1980 έως τον Ιούνιο του 2017 (450 παρατηρήσεις) ενώ για το φυσικό αέριο αφορούν την περίοδο από τον Ιανουάριο του 1985 έως τον Ιούνιο του 2017 (390 παρατηρήσεις) για την Ρωσία και την περίοδο από τον Ιανουάριο του 1991 έως τον Ιούνιο του 2017 (318 παρατηρήσεις) για τις ΗΠΑ. Από τα δεδομένα αυτά το 80% περίπου χρησιμοποιήθηκε ως σετ εκπαίδευσης και το υπόλοιπο 20% ως test set. Για

την σύγκριση των μοντέλων χρησιμοποιήθηκαν τα κριτήρια, το Root Mean Square (RMSE) και το Mean Absolute Percentage Error (MAPE).

Τα αποτελέσματα της έρευνας έδειξαν ότι το μοντέλο μηχανικής μάθησης παρουσιάζουν καλύτερη ικανότητα πρόβλεψης από το υβριδικό καθώς εμφανίζουν μικρότερες τιμές στα σφάλματα. Όσον αφορά τα μοντέλα μηχανικής μάθησης το μοντέλο Random Forest είναι πιο αποδοτικό από το Νευρωνικό Δίκτυο.

Data-Driven Natural Gas Spot Price Forecasting with Least Squares Regression Boosting Algorithm

Το φυσικό αέριο συχνά περιγράφεται ως το καθαρότερο ορυκτό καύσιμο. Η κατανάλωση φυσικού αερίου αυξάνεται ραγδαία, οπότε η ακριβής πρόβλεψη της τιμής του θα ωφελούσε σημαντικά τη διαχείριση ενέργειας, την οικονομική ανάπτυξη και τη διατήρηση του περιβάλλοντος. Η συγκεκριμένη έρευνα των Motting Su et.al. (2019) χρησιμοποιεί τον αλγόριθμο Least Squares Regression Boosting (LSBoost) για να αξιολογήσει την ικανότητα του στο να προβλέπει τις συγκεκριμένες τιμές.

Τα δεδομένα που χρησιμοποιήθηκαν ήταν οι τιμές του Henry Hub φυσικού αερίου σε διαφορετικές συχνότητες από τον Ιανουάριο του 2001 έως τον Δεκέμβριο του 2017. Δηλαδή αφορούσαν τις ημερήσιες, εβδομαδιαίες και μηνιαίες τιμές. Μετά από επεξεργασία τα δεδομένα περιείχαν 4260 παρατηρήσεις για τις ημερήσιες τιμές, 886 παρατηρήσεις για τις εβδομαδιαίες και 204 για τις μηνιαίες. Επιπλέον χρησιμοποιήθηκαν και κάποιες βοηθητικές μεταβλητές όπου επηρεάζουν και αυτές την τιμή του φυσικού αερίου. Αυτές οι μεταβλητές ήταν οι ακόλουθες: Heating Oil Prices (HO), WTI oil Prices (WTI), Baker Hughes US Natural Gas Rotary Rig Count (NGRRC), Total US Natural Gas Marketed Production (NGMP), Total US Natural Gas Consumption (NGC), Total US Natural Gas Underground Storage Capacity (NGUSC), and Total US Natural Gas Imports (NGI). Ο αλγόριθμος αυτός συγκρίθηκε και με κάποια άλλα γνωστά μοντέλα τα οποία είναι το Linear Regression, το Linear Support Vector Machine, το Quadratic Support Vector Machine και το Cubic Support Vector Machine. Η αξιολόγηση του αλγορίθμου καθώς και η σύγκριση του με τα υπόλοιπα μοντέλα έγινε με βάση κάποια κριτήρια. Αυτά ήταν το R-square (R^2), το Mean Absolute Error (MAE), το Mean Square Error (MSE) και το Root-Mean Square Error (RMSE).

Τα αποτελέσματα της έρευνας έδειξαν ότι ο αλγόριθμος LSBoost είναι αρκετά ικανός στην πρόβλεψη της τιμής συγκεκριμένης μορφής ενέργειας και μάλιστα υπερσχύει από τα υπόλοιπα μοντέλα που συγκρίθηκε. Αυτό φαίνεται αφού παρουσιάζει την υψηλότερη τιμή R^2 και την χαμηλότερη τιμή MAE, MSE και RMSE σε σχέση με τα άλλα μοντέλα.

An Advanced Deep Learning Model for Short-Term Forecasting U.S. Natural Gas Price and Movement

Το φυσικό αέριο αποτελεί ένα από τα πιο ενεργά εμπορεύσιμα ενεργειακά προϊόντα με σημαντικό αντίκτυπο σε πολλές χρηματοοικονομικές δραστηριότητες του κόσμου. Η ακριβής πρόβλεψη της τιμής του και η κατεύθυνση των μεταβολών αυτής της τιμής θεωρείται απαραίτητη, καθώς αυτές οι προβλέψεις χρησιμοποιούνται στον σχεδιασμό της ενεργειακής βιωσιμότητας, στις συναλλαγές εμπορευμάτων και στη λήψη αποφάσεων, καλύπτοντας τόσο την πλευρά της προσφοράς όσο και της ζήτησης της αγοράς φυσικού αερίου.

Η συγκεκριμένη έρευνα των Ioannis E. Livieris et.al. (2020) παρουσιάζει ένα μοντέλο πρόβλεψης, επονομαζόμενο CNN-LSTM, το οποίο χρησιμοποιεί προχωρημένες τεχνικές βαθιάς μάθησης για την βραχυπρόθεσμη πρόβλεψη της τιμής του φυσικού αερίου καθώς και την μεταβολή της κατεύθυνσης της τιμής αυτής. Τα δεδομένα που χρησιμοποιήθηκαν αφορούσαν την ημερήσια τιμή του φυσικού αερίου σε δολάρια από τον Ιανουάριο του 2015 έως τον Δεκέμβριο του 2019. Για την εκπαίδευση του μοντέλου χρησιμοποιήθηκαν τα δεδομένα από 1 Ιανουαρίου του 2015 έως 31 Δεκεμβρίου του 2018 (1129 ημέρες) ενώ για τον έλεγχο του μοντέλου χρησιμοποιήθηκαν τα δεδομένα από 1 Ιανουαρίου του 2018 έως 31 Δεκεμβρίου του 2019. Το μοντέλο αυτό συγκρίθηκε με άλλα επτά μοντέλα για να αξιολογηθεί η προβλεπτική του ικανότητα. Τα μοντέλα αυτά ήταν ένα μοντέλο Artificial Neural Network (ANN), ένα Support Vector Regression (SVR), ένα Decision Tree Regression (DTR) καθώς και 4 παραδοχές ενός μοντέλου Long Short-Term Memory (LSTM) με διαφορετικούς παράγοντες το καθένα. Για την αξιολόγηση του μοντέλου καθώς και την σύγκριση του με τα άλλα μοντέλα χρησιμοποιήθηκαν δύο κριτήρια, το Root Mean Square Error (RMSE) και το Mean Absolute Error (MAE). Ενώ για την πρόβλεψη της μεταβολής της κατεύθυνσης της τιμής χρησιμοποιήθηκαν άλλα τρία κριτήρια, το Accuracy (Acc), το Area Under Curve (AUC) και το F1-score (F1).

Τα αποτελέσματα της έρευνας έδειξαν τόσο το μοντέλο που παρουσιάζει η έρευνα όσο και το μοντέλο SVR εμφανίζουν τις χαμηλότερες τιμές στα RMSE και MAE. Δηλαδή έχουν καλύτερη προβλεπτική ικανότητα από τα υπόλοιπα μοντέλα. Όσον αφορά την πρόβλεψη της μεταβολής της κατεύθυνσης της τιμής του φυσικού αερίου το μοντέλο CNN-LSTM είχε την καλύτερη απόδοση καθώς είχε τις μεγαλύτερες τιμές στα ACC, AUC και F1-score.

Multistep-ahead forecasting of coal prices using a hybrid deep learning model

Ένα ακριβές μοντέλο πρόβλεψης για τις μελλοντικές διακυμάνσεις της τιμής του άνθρακα παρέχει κρίσιμες πληροφορίες και έγκαιρη προειδοποίηση για την κυβέρνηση ώστε να παρέχει σταθερό εφοδιασμό ενέργειας. Επομένως η συγκεκριμένη έρευνα των Zakaria Alameer et.al. (2020) προτείνει ένα υβριδικό μοντέλο (LSTM-DNN) όπου συνδυάζει ένα Long Short-Term Memory (LSTM) και ένα Deep Neural Network (DNN) για την πρόβλεψη της μηνιαίας τιμής του άνθρακα. Τα δεδομένα που χρησιμοποιήθηκαν αφορούσαν την μηνιαία τιμή του Αυστραλιανού άνθρακα από τον

Ιανουάριο του 1989 έως τον Δεκέμβριο του 2018 (360 μήνες). Για την εκπαίδευση του μοντέλου χρησιμοποιήθηκαν 252 μήνες, δηλαδή το 70% των αρχικών δεδομένων (από Ιανουάριο του 1989 έως Δεκέμβριο του 2009), ενώ για τον έλεγχο του μοντέλου χρησιμοποιήθηκαν 108 μήνες, δηλαδή το 30% των αρχικών δεδομένων (από Ιανουάριο του 2010 έως Δεκέμβριο του 2018). Επιπλέον για να βελτιωθεί η ακρίβεια του συγκεκριμένου μοντέλου προστέθηκαν εννέα μεταβλητές οι οποίες έχουν ισχυρή συσχέτιση με την τιμή του άνθρακα. Αυτές ήταν οι ισοτιμίες του Αυστραλιανού Δολαρίου (AUD), του Ρουπιού Ινδονησίας (IDR) και του Κινέζικου Γουάν (RMB) με το Δολάριο Αμερικής (USD) καθώς και οι μηνιαίες τιμές του αργού πετρελαίου, του φυσικού αερίου, του χαλκού, του σίδηρου, του ασημιού και του χρυσού. Έπειτα δημιουργήθηκε ένας πίνακας συσχέτισης όπου δείχνει κατά πόσο αυτές οι μεταβλητές επηρεάζουν την τιμή του άνθρακα.

Το προτεινόμενο μοντέλο συγκρίθηκε με άλλα δύο μοντέλα για διάφορους χρονικούς ορίζοντες, ένα Multilayer Perceptron Neural Network (MLP) και ένα Support Vector Machine (SVM) έτσι ώστε να συγκριθεί η απόδοση του με άλλα ανταγωνιστικά. Για την αξιολόγηση και την σύγκριση των μοντέλων χρησιμοποιήθηκαν τρία κριτήρια, το Mean Square Error (MSE), το Root Mean Square Error (RMSE) και το Mean Absolute Error (MAE).

Όπως παρουσιάζεται στους πίνακες της έρευνας το προτεινόμενο μοντέλο (LSTM-DNN) εμφανίζει τις μικρότερες τιμές σε όλα τα παραπάνω κριτήρια και για όλους τους χρονικούς ορίζοντες. Άρα το συγκεκριμένο μοντέλο παρουσιάζει την μεγαλύτερη ικανότητα πρόβλεψης από τα άλλα δύο ανταγωνιστικά. Αξίζει όμως να αναφερθεί ότι όσο ο ορίζοντας της πρόβλεψης αυξάνεται, τόσο μειώνεται η ακρίβεια της πρόβλεψης.

Development of MI-ANFIS-BBO Model for Forecasting Crude Oil Price

Η πρόβλεψη των τιμών του αργού πετρελαίου είναι ένα σημαντικό έργο στον τομέα της ενεργειακής έρευνας, επειδή το αργό πετρέλαιο είναι το σημαντικότερο εμπόρευμα στον κόσμο με υψηλό επίπεδο μεταβλητότητας. Αυτή η μελέτη του Quang Hung Do (2020) προτείνει το Adaptive Neuro-Fuzzy Inference System (ANFIS) με παραμέτρους βελτιστοποιημένες από τον αλγόριθμο Biogeography-Based Optimization (BBO) και την τεχνική Mutual Information (MI) για την πρόβλεψη της τιμής του αργού πετρελαίου. Τα δεδομένα που χρησιμοποιήθηκαν αφορούσαν την τιμή του West Texas Intermediate (WTI) αργού πετρελαίου και του Brent αργού πετρελαίου για την περίοδο από τον Ιανουάριο του 2000 έως τον Σεπτέμβριο του 2018. Τα δεδομένα αποτελούνται από τον εβδομαδιαίο μέσο όρο της ημερήσιας τιμής κλεισίματος ορίζοντας έτσι ένα σύνολο από 970 παρατηρήσεις. Το προτεινόμενο μοντέλο συγκρίθηκε με άλλα τρία μοντέλα για την αξιολόγηση της απόδοσης του. Τα μοντέλα αυτά ήταν, ένα Artificial Neural Network (ANN) ένα μοντέλο ANFIS και ένα μοντέλο Linear Regression. Για την αξιολόγηση και την σύγκριση των μοντέλων χρησιμοποιήθηκαν πέντε κριτήρια. Αυτά ήταν το Root Mean Squared Error (RMSE), το Mean Absolute Error (MAE), το Relative Absolute Error (RAE), το Root Relative Squared Error (RRSE) και το Correlation Coefficient (R).

Η έρευνα καταλήγει ότι το προτεινόμενο μοντέλο (MI-ANFIS-BBO) παρουσιάζει ανώτερη απόδοση πρόβλεψης σε σχέση με τα υπόλοιπα μοντέλα καθώς εμφανίζει την μεγαλύτερη τιμή στο κριτήριο R και τις μικρότερες τιμές στα υπόλοιπα κριτήρια τόσο για την περίπτωση του WTI αργού πετρελαίου όσο και του Brent.

Daily crude oil price forecasting model using arima, generalized autoregressive conditional heteroscedastic and Support Vector Machines

Η πρόβλεψη της τιμής του αργού πετρελαίου αποκτά ολοένα και μεγαλύτερο ενδιαφέρον παγκοσμίως. Αυτό οφείλεται κυρίως στην οικονομική αξία που αποδίδεται στο προϊόν. Επομένως σκοπός της συγκεκριμένης έρευνας των Rana Abdullah Ahmed & Ani Shabri (2014) είναι η παρουσίαση ενός μοντέλου πρόβλεψης της τιμής αυτής, βασισμένο στα Support Vector Machines (SVM). Τα δεδομένα που χρησιμοποιήθηκαν αφορούσαν τις ημερήσιες τιμές του West Texas Intermediate (WTI) αργού πετρελαίου από την περίοδο 1 Ιανουαρίου 1986 έως 30 Σεπτεμβρίου 2006. Το προτεινόμενο μοντέλο συγκρίθηκε με τα μοντέλα Autoregressive Integrated Moving Average (ARIMA) και Generalized Autoregressive Conditional Heteroscedastic model (GARCH) με σκοπό την αξιολόγηση της προβλεπτικής του ικανότητας. Για την αξιολόγηση του μοντέλου καθώς και για την σύγκριση των μοντέλων χρησιμοποιήθηκαν τα κριτήρια Mean Absolute Error (MAE) και Root Mean Square Error (RMSE).

Τα αποτελέσματα της έρευνας δείχνουν ότι το προτεινόμενο μοντέλο παρουσιάζει την βέλτιστη απόδοση σε σχέση με τα άλλα μοντέλα. Αυτό αιτιολογείται από τις τιμές των κριτηρίων καθώς αυτές είναι μικρότερες για το συγκεκριμένο μοντέλο.

A novel algorithm for prediction of crude oil price variation based on soft computing

Στην συγκεκριμένη έρευνα των Ali Ghaffari & Samaneh Zare (2009) χρησιμοποιήθηκε ένα μοντέλο ANFIS για την πρόβλεψη της μεταβολής της τιμής του αργού πετρελαίου. Το μοντέλο αυτό υλοποιήθηκε δύο φορές, στην μία εκ των οποίων τα δεδομένα είχαν υποστεί μία διαδικασία που λέγεται smoothing. Η διαδικασία αυτή χρησιμοποιήθηκε προκειμένου να μειωθεί η επίδραση των βραχυπρόθεσμων διαταραχών διατηρώντας τα κύρια και μακροπρόθεσμα χαρακτηριστικά του δυναμικού συστήματος. Τα δεδομένα που χρησιμοποιήθηκαν αφορούσαν την ημερήσια τιμή του West Texas Intermediate (WTI) αργού πετρελαίου από την περίοδο 5 Ιανουαρίου 2004 έως 30 Απριλίου 2007 (828 δεδομένα). Για την εκπαίδευση του μοντέλου χρησιμοποιήθηκε το 80% των δεδομένων ενώ το υπόλοιπο 20% χρησιμοποιήθηκε ως test set. Η προβλεπόμενη τιμή συγκρινόταν κάθε φορά με την πραγματική τιμή και αν οι δύο αυτές τιμές παρουσίαζαν την ίδια μεταβολή τότε το αποτέλεσμα της πρόβλεψης οριζόταν ως “TRUE” αλλιώς αν οι τιμές παρουσίαζαν αντίθετη μεταβολή το αποτέλεσμα οριζόταν ως “FALSE”. Για την αξιολόγηση των δύο υλοποιήσεων

χρησιμοποιήθηκε το Percentage of the Correct Prediction (PCP) το οποίο υπολόγιζε το ποσοστό των προβλέψεων που ορίστηκαν ως “TRUE” προς το σύνολο όλων των προβλέψεων. Τα αποτελέσματα της έρευνας δείχνουν ότι η υλοποίηση του μοντέλου ANFIS με την διαδικασία smoothing στα αρχικά δεδομένα παρουσίασε καλύτερη προβλεπτική ικανότητα αφού το κριτήριο PCP ήταν μεγαλύτερο.

Developing a new approach for forecasting the trends of oil price

Η συγκεκριμένη έρευνα των Hossein Mombeini & Abdolreza Yazdani-Chamzini (2014) παρουσιάζει ένα υβριδικό μοντέλο πρόβλεψης που αποτελείται από τα μοντέλα Autoregressive Integrated Moving Average (ARIMA) και Adaptive Neuro-Fuzzy Inference System (ANFIS). Τα δεδομένα που χρησιμοποιήθηκαν ήταν οι μηνιαίες τιμές του West Texas Intermediate (WTI) αργού πετρελαίου από τον Απρίλιο του 1996 έως τον Νοέμβριο του 2005 (116 παρατηρήσεις). Για την εκπαίδευση του μοντέλου χρησιμοποιήθηκαν τα δεδομένα έως τον Οκτώβριο του 2003 ενώ τα υπόλοιπα χρησιμοποιήθηκαν ως test set. Για να βρεθεί το μοντέλο ARIMA με τις καλύτερες παραμέτρους, που στην συνέχεια θα χρησιμοποιηθεί στο υβριδικό, δοκιμάστηκαν διάφορες τιμές των παραμέτρων αυτών και αξιολογήθηκαν με βάση τα κριτήρια Akaike info criterion (AIC), Schwarz-Bayesian criterion (BIC) και Hannan-Quinn criterion (HQC). Στην συνέχεια το υβριδικό μοντέλο υλοποιήθηκε για διάφορους αριθμούς μεταβλητών εισόδου και για διάφορους αριθμούς συναρτήσεων συμμετοχής (MFs). Για να αξιολογηθούν οι υλοποιήσεις αυτές καθώς και για να συγκριθούν με το βέλτιστο απλό μοντέλο ARIMA που προέκυψε παραπάνω χρησιμοποιήθηκαν τα κριτήρια Coefficient of Determination (R^2), Persistence Index (PI) και Mean Absolute Percentage Error (MAPE). Από τα αποτελέσματα φαίνεται ότι το υβριδικό μοντέλο με μία μεταβλητή εισόδου και επτά συναρτήσεις συμμετοχής υπερέχει των υπολοίπων.

Crude Oil Price Forecasting Using Machine Learning

Η Ινδία είναι ένας από τους μεγαλύτερους καταναλωτές πετρελαίου στον κόσμο. Μεταξύ όλων των βιομηχανικών γραμμών, το πετρέλαιο και η βιομηχανία φυσικού αερίου έχει σημαντικό αντίκτυπο στην ανάπτυξη της οικονομίας και του Ακαθάριστου Εγχώριου Προϊόντος της χώρας (ΑΕΠ) μιας και αντιπροσωπεύει τουλάχιστον το 15% αυτού. Επομένως η συγκεκριμένη έρευνα του Shambulingappa H S (2020) προτείνει ένα μοντέλο Autoregressive Integrated Moving Average (ARIMA) για την πρόβλεψη της τιμής του αργού πετρελαίου. Αν και η έρευνα δεν διευκρινίζει τον χρονικό ορίζοντα των δεδομένων που χρησιμοποιεί, αυτός φαίνεται να είναι λίγο πριν το 1988 έως το 2016 από τα γραφήματα που χρησιμοποιεί. Το μοντέλο ARIMA συγκρίθηκε με ένα μοντέλο Autoregressive (AR) και ένα μοντέλο Moving Average (MA) με σκοπό την αξιολόγηση της προβλεπτικής του ικανότητας. Για να γίνει η αξιολόγηση αυτή χρησιμοποιήθηκε το κριτήριο Mean Square Error (MSE). Τα αποτελέσματα της έρευνας παρουσιάζουν το μοντέλο ARIMA ως το μοντέλο με την καλύτερη προβλεπτική ικανότητα, στην πρόβλεψη του αργού πετρελαίου, καθώς εμφανίζει την μικρότερη τιμή στο κριτήριο MSE από τα άλλα δύο.

Improving Adaptive Neuro-Fuzzy Inference System Based on a Modified Salp Swarm Algorithm Using Genetic Algorithm to Forecast Crude Oil Price

Αυτή η έρευνα των Mohamed Abd Elaziz et.al. (2020) παρουσιάζει ένα νέο μοντέλο πρόβλεψης για την τιμή του αργού πετρελαίου καθώς η τιμή αυτή έχει μεγάλη επίδραση στις οικονομίες και τις χώρες. Η προτεινόμενη μέθοδος εξαρτάται από τη βελτίωση της απόδοσης του Adaptive Neuro-Fuzzy Inference System (ANFIS) χρησιμοποιώντας έναν τροποποιημένο αλγόριθμο Salp Swarm (SSA). Το SSA προσομοιώνει τις συμπεριφορές του σμήνους σαλπών στη φύση κατά την αναζήτηση τροφής και έχει αναπτυχθεί ως μια παγκόσμια μέθοδος βελτιστοποίησης. Ωστόσο, η SSA εξακολουθεί να έχει ορισμένους περιορισμούς, όπως να παγιδευτεί σε ένα τοπικό σημείο. Επομένως, αυτή η εργασία χρησιμοποιεί έναν γενετικό αλγόριθμο (GA) για τη βελτίωση της συμπεριφοράς του SSA. Το προτεινόμενο μοντέλο (GA-SSA-ANFIS) στοχεύει στον προσδιορισμό των κατάλληλων παραμέτρων για το ANFIS χρησιμοποιώντας τον αλγόριθμο GA-SSA αφού αυτές οι παράμετροι θεωρούνται ως ο κύριος παράγοντας που επηρεάζει τη διαδικασία πρόβλεψης του ANFIS. Τα αποτελέσματα του GA-SSA-ANFIS συγκρίνονται με άλλα μοντέλα, συμπεριλαμβανομένου του παραδοσιακού μοντέλου ANFIS, του ANFIS με βάση το GA (GA-ANFIS), του ANFIS με βάση το SSA (SSA-ANFIS), του ANFIS με βάση τη βελτιστοποίηση σμήνους σωματιδίων (PSO-ANFIS) και του ANFIS με βάση τη βελτιστοποίηση του γκριζού λύκου (GWO-ANFIS). Επίσης συγκρίνεται με το παραδοσιακό μοντέλο Extreme Learning Machine (ELM), το ELM με βάση το PSO (PSO-ELM), το ELM με βάση το GA (GA-ELM) και το ELM με βάση το GWO (GWO-ELM). Τα δεδομένα που χρησιμοποιήθηκαν ήταν οι μηνιαίες τιμές του West Texas Intermediate (WTI) αργού πετρελαίου από τον Ιανουάριο του 1989 έως τον Δεκέμβριο του 2018 (360 παρατηρήσεις). Για την εκπαίδευση του μοντέλου χρησιμοποιήθηκε το 70% των δεδομένων ενώ το υπόλοιπο 30% χρησιμοποιήθηκε ως test set. Για την βελτίωση της απόδοσης του προτεινόμενου μοντέλου χρησιμοποιήθηκαν άλλες εννέα μεταβλητές που φαίνεται να επηρεάζουν την τιμή του αργού πετρελαίου. Για την αξιολόγηση και την σύγκριση των μοντέλων χρησιμοποιήθηκαν πέντε κριτήρια. Αυτά ήταν το Root Mean Squared Error (RMSE), το Mean Absolute Error (MAE), το Mean Square Error (MSE), το Standard Deviation (STD) και το Determination Coefficient (R^2). Τα αποτελέσματα δείχνουν την υπεροχή και τις υψηλές επιδόσεις του GA-SSA-ANFIS έναντι των άλλων μοντέλων στην πρόβλεψη των τιμών του αργού πετρελαίου.

Opec Oil Price Prediction Using Anfis

Στην συγκεκριμένη έρευνα των Ehsan Lotfi & M R Karimi (2014), αναπτύσσεται ένα μοντέλο Adaptive Neuro-Fuzzy Inference System (ANFIS) για την πρόβλεψη των τιμών του πετρελαίου του Οργανισμού Εξαγωγών Πετρελαιοπαραγωγών Χωρών (OPEC). Η νέα πτυχή του συγκεκριμένου μοντέλου είναι το προτεινόμενο σύνολο χαρακτηριστικών που χρησιμοποιείται για να τροφοδοτήσει το ANFIS. Αυτά τα χαρακτηριστικά περιλαμβάνουν τις μηνιαίες τιμές του Ποσοστό πληθωρισμού ΗΠΑ,

του Επιτοκίου, του Επιπέδου παραγωγής πετρελαίου του OPEC, της Τιμής του Χρυσού, της Τιμής του Ασημιού, του Δείκτη Αγοράς, του Δείκτη δολαρίου των ΗΠΑ, καθώς και της τιμής του πετρελαίου Αμερικής, F.O.B και OPEC. Τα δεδομένα αυτά αφορούσαν την περίοδο από Σεπτέμβριο 2001 έως τον Δεκέμβριο 2012 (136 μήνες). Για την εκπαίδευση του μοντέλου χρησιμοποιήθηκαν τα δεδομένα από Σεπτέμβριο 2001 έως Νοέμβριο 2009 ενώ τα υπόλοιπα χρησιμοποιήθηκαν ως test set. Το προτεινόμενο μοντέλο συγκρίθηκε με ένα μοντέλο Artificial Neural Network (ANN) με σκοπό την αξιολόγηση της προβλεπτικής του ικανότητας. Για την αξιολόγηση του μοντέλου καθώς και για την σύγκριση των μοντέλων χρησιμοποιήθηκαν τα κριτήρια Correlation Coefficient (COR) και Root Mean Square Error (RMSE). Σύμφωνα με τα αποτελέσματα, το ANFIS με το προτεινόμενο σύνολο χαρακτηριστικών δείχνει μεγαλύτερη ακρίβεια από τα συμβατικά νευρωνικά δίκτυα στην πρόβλεψη της τιμής του πετρελαίου.

Multi-Step-Ahead Carbon Price Forecasting Based on Variational Mode Decomposition and Fast Multi-Output Relevance Vector Regression Optimized by the Multi-Objective Whale Optimization Algorithm

Η ακριβής και σταθερή πρόβλεψη των τιμών του άνθρακα είναι ζωτικής σημασίας για τη χάραξη πολιτικής από τους κυβερνήτες και απαραίτητη για τη λήψη επενδυτικών αποφάσεων για τους συμμετέχοντες στην αγορά, κάτι που είναι σημαντικό για την προώθηση της ανάπτυξης των αγορών άνθρακα και τη μείωση των εκπομπών άνθρακα στην Κίνα. Ωστόσο, είναι δύσκολο να βελτιωθεί η ακρίβεια πρόβλεψης της τιμής του άνθρακα λόγω της μη γραμμικότητας και των μη στάσιμων χαρακτηριστικών του, ειδικά στην πρόβλεψη πολλαπλών βημάτων. Στην συγκεκριμένη έρευνα των Shenghua Xiong et.al. (2019), προτείνεται ένα υβριδικό μοντέλο πρόβλεψης πολλαπλών βημάτων που βασίζεται σε Variational Mode Decomposition (VMD), σε Fast Multi-Output Relevance Vector Regression (FMRVR) και στον Multi-Objective Whale Optimization Algorithm (MOWOA). Το προτεινόμενο υβριδικό μοντέλο πρόβλεψης εφαρμόζεται σε σειρές τιμών άνθρακα από τρεις μεγάλες περιφέρειες ανταλλαγής άνθρακα στην Κίνα. Αυτές είναι η Shenzhen Emission Exchange (SZA2016), η Guangzhou Emissions Exchange (GDEA) και η Hubei Emissions Exchange (HBEA). Τα δεδομένα αφορούσαν τις ημερήσιες τιμές άνθρακα για την περίοδο από 1 Σεπτεμβρίου 2016 έως 11 Σεπτεμβρίου 2018 (496 παρατηρήσεις). Για την εκπαίδευση του μοντέλου χρησιμοποιήθηκε περίπου το 70% των δεδομένων ενώ το υπόλοιπο 30% χρησιμοποιήθηκε ως test set. Το προτεινόμενο μοντέλο συγκρίθηκε με τα μοντέλα FMRVR-MOWOA, MOTP-MOWOA (MOTP = Multi-Output student-t Process Regression), MOGP-MOWOA (MOGP = Multi-Output Gaussian Process Regression), Multi-Output Support Vector Regression (MSVR) και Back Propagation Neural Network. (BPNN). Για την αξιολόγηση και την σύγκριση των μοντέλων χρησιμοποιήθηκαν τρία κριτήρια. Αυτά ήταν το Root Mean Squared Error (RMSE), το Mean Absolute Error (MAE) και το Mean Absolute Percentage Error (MAPE). Τα αποτελέσματα δείχνουν ότι το προτεινόμενο μοντέλο VMD-FMRVR-MOWOA

επιτυγχάνει καλύτερη απόδοση σε σύγκριση με τα άλλα μοντέλα πολλαπλών εξόδων όσον αφορά την ακρίβεια και τη σταθερότητα πρόβλεψης.

A Novel Hybrid AI System Framework for Crude Oil Price Forecasting

Σε αυτή τη έρευνα των Shouyang Wang et.al. (2004), αναπτύσσεται ένα σύστημα υβριδικής τεχνητής νοημοσύνης που αποτελείται από ένα Artificial Neural Network (ANN) και ένα Rule-based Expert System (RES) με τεχνικές Web-Based Text Mining (WTM). Η προτεινόμενη προσέγγιση πρόβλεψης υβριδικής τεχνητής νοημοσύνης γενικά αποτελείται από τέσσερα κύρια βήματα. Πρώτα απ' όλα, χρησιμοποιώντας την τεχνική εξόρυξης κειμένου μέσω web, δύναται να ληφθούν ορισμένες πρόσφατες πληροφορίες που επηρεάζουν την τιμή του πετρελαίου. Στη συνέχεια, συγκρίνοντας τις ανακτηθείσες ή συλλεγμένες πληροφορίες με τα προκαθορισμένα μοτίβα, μπορεί να κριθεί αν υπάρχουν σημαντικά γεγονότα που επηρεάζουν την αστάθεια της τιμής του πετρελαίου. Στη συνέχεια, εάν δεν υπάρχουν σχετικά μοτίβα, τότε μπορεί να εφαρμοστεί άμεσα πρόβλεψη βασισμένη σε ANN για την τιμή του πετρελαίου χρησιμοποιώντας τα ιστορικά δεδομένα. Εάν υπάρχουν σημαντικά γεγονότα στις ανακτηθείσες πληροφορίες, χρησιμοποιείται η πρόβλεψη χρονοσειρών βασισμένη σε ANN για την πρόβλεψη της τιμής του πετρελαίου σε συνδυασμό με το RES για την πρόβλεψη της αστάθειας της τιμής αυτής με βάση κάποιο σημαντικό παράγοντα που την επηρεάζει. Με την εφαρμογή των δύο μονάδων, μπορεί να ληφθεί η προβλεπόμενη τιμή του πετρελαίου.

Τα ιστορικά δεδομένα που χρησιμοποιήθηκαν αφορούσαν την μηνιαία τιμή του West Texas Intermediate (WTI) αργού πετρελαίου για την περίοδο από τον Ιανουάριο του 1970 έως τον Δεκέμβριο του 2002 με συνολικά 396 παρατηρήσεις. Από αυτό το σύνολο οι 360 παρατηρήσεις χρησιμοποιήθηκαν για εκπαίδευση ενώ οι υπόλοιπες 36 χρησιμοποιήθηκαν ως test set. Το προτεινόμενο μοντέλο συγκρίθηκε με ένα απλό ANN με σκοπό την αξιολόγηση των επιδόσεων του. Για την αξιολόγηση αυτή χρησιμοποιήθηκαν τα κριτήρια Root Mean Square Error (RMSE) και Direction Change Statistics (Dstat). Τα αποτελέσματα της αξιολόγησης έδειξαν ότι η προτεινόμενη προσέγγιση είναι σημαντικά αποτελεσματική και πρακτικά εφικτή. Ως εκ τούτου, το νέο μοντέλο πρόβλεψης υβριδικής τεχνητής νοημοσύνης μπορεί να χρησιμοποιηθεί ως ένα κατάλληλο εργαλείο για την πρόβλεψη της τιμής του αργού πετρελαίου για τη βελτίωση της ακρίβειας των προβλέψεων.

Improved EEMD-based crude oil price forecasting using LSTM networks

Λαμβάνοντας υπόψη την πραγματική ζήτηση για την πρόβλεψη της τιμής του αργού πετρελαίου, σε αυτή την έρευνα των Yu-Xi Wu et.al. (2019) προτείνεται ένα νέο μοντέλο που βασίζεται σε Ensemble Empirical Mode Decomposition (EEMD) και σε Long Short-Term Memory (LSTM). Τα δεδομένα που χρησιμοποιήθηκαν αφορούσαν την ημερήσια τιμή του West Texas Intermediate (WTI) αργού πετρελαίου για την

περίοδο από 6 Ιανουαρίου του 1986 έως 6 Ιουνίου του 2016 (7620 παρατηρήσεις). Για την εκπαίδευση του μοντέλου χρησιμοποιήθηκε το 80% των δεδομένων ενώ το υπόλοιπο 20% χρησιμοποιήθηκε ως test set.

Αρχικά συγκρίθηκαν πέντε μοντέλα με ένα απλό LSTM και στην συνέχεια δημιουργήθηκαν και συγκρίθηκαν υβριδικά μοντέλα που αποτελούνταν από το EEMD και καθένα από τα υπόλοιπα μοντέλα (το προτεινόμενο μοντέλο της έρευνας είναι το EEMD-LSTM). Τα μοντέλα που χρησιμοποιήθηκαν για την σύγκριση ήταν ένα Extreme Learning Machine (ELM), ένα Least Squares Support Vector Regression (LSSVR), ένα Artificial Neural Network (ANN), ένα Auto-Regressive Integrated Moving Average (ARIMA) και ένα Kernel Ridge Regression (KRR). Για την σύγκριση αυτή χρησιμοποιήθηκαν τα κριτήρια Root Mean Squared Error (RMSE), Mean Absolute Percent Error (MAPE) και Directional Statistic (Dstat). Τα αποτελέσματα της έρευνας δείχνουν ότι το προτεινόμενο υβριδικό μοντέλο επιτυγχάνει καλύτερη απόδοση σε σύγκριση με τα άλλα υβριδικά μοντέλα καθώς παρουσιάζει τις μικρότερες τιμές στα RMSE και MAPE και την μεγαλύτερη τιμή στο Dstat.

Assessing Potentiality of Support Vector Machine Method in Crude Oil Price Forecasting

Η πρόβλεψη των τιμών του αργού πετρελαίου είναι ένα από τα πιο σημαντικά θέματα στον τομέα της ενεργειακής έρευνας. Αντίστοιχα, πολλές μέθοδοι όπως στατιστικές, οικονομετρικές και έξυπνες προσεγγίσεις εφαρμόζονται για την πρόβλεψη της τιμής του αργού πετρελαίου. Σε αυτή την έρευνα των Lean Yu et.al. (2017) χρησιμοποιήθηκε ένας αλγόριθμος Support Vector Machine (SVM) για να εξεταστεί η δυνατότητα του στην πρόβλεψη της τιμής του αργού πετρελαίου. Για το σκοπό αυτό, πέντε διαφορετικά μοντέλα πρόβλεψης χρησιμοποιούνται στη μελέτη, ένα Feed-forward Neural Network (FNN), ένα Auto-Regressive Integrated Moving Average (ARIMA), ένα Fractional Integrated ARIMA (ARFIMA), ένα ARFIMA με Markov-Switching (MS-ARFIMA), και ένα μοντέλο Random Walk (RW). Τα δεδομένα που χρησιμοποιήθηκαν αφορούσαν τις μηνιαίες τιμές τόσο του West Texas Intermediate (WTI) αργού πετρελαίου όσο και του Brent για την περίοδο από τον Ιανουάριο του 2009 έως τον Ιούλιο του 2008 (223 παρατηρήσεις). Για την σύγκριση των μοντέλων χρησιμοποιήθηκαν τα κριτήρια Root Mean Squared Error (RMSE) και Directional Statistic (Dstat).

Τα αποτελέσματα της έρευνας δείχνουν ότι το μοντέλο SVM υπερτερεί των άλλων πέντε μεθόδων, υπονοώντας ότι είναι ένας αρκετά καλός υποψήφιος για την πρόβλεψη της τιμής του αργού πετρελαίου.

Daily Crude Oil Price Forecasting Using Hybridizing Wavelet and Artificial Neural Network Model

Στην συγκεκριμένη έρευνα των Ani Shabri & Ruhaidah Samsudin (2014) προτείνεται μια νέα μέθοδος που βασίζεται στην σύνθεση ενός Discrete Wavelet Transform με ένα Artificial Neural Network (WANN) για την ημερήσια πρόβλεψη των τιμών του αργού πετρελαίου. Τα δεδομένα που χρησιμοποιήθηκαν αφορούσαν τις ημερήσιες του Brent αργού πετρελαίου για την περίοδο από 20 Μαΐου 1987 έως 30 Σεπτεμβρίου 2006 και του West Texas Intermediate (WTI) αργού πετρελαίου για την περίοδο από 1 Ιανουαρίου 1986 έως 30 Σεπτεμβρίου 2006. Όσον αφορά στην εκπαίδευση του μοντέλου, για το Brent αργό πετρέλαιο, χρησιμοποιήθηκε περίπου το 80% ενώ για το WTI χρησιμοποιήθηκε περίπου το 70% των δεδομένων, ενώ τα υπόλοιπα χρησιμοποιήθηκαν ως test set.

Η σχετική απόδοση του μοντέλου WANN συγκρίθηκε με ένα απλό μοντέλο ANN για την πρόβλεψη αργού πετρελαίου, τόσο για το West Texas Intermediate (WTI) όσο και για τις τιμές αργού πετρελαίου Brent. Για την αξιολόγηση αυτή χρησιμοποιήθηκαν τα κριτήρια Root Mean Square Error (RMSE) και Mean Absolute Percent Error (MAPE). Και στις δύο περιπτώσεις, το μοντέλο WANN βρέθηκε να παρέχει πιο ακριβείς προβλέψεις για τις τιμές του αργού πετρελαίου από το μεμονωμένο μοντέλο ANN.

Oil price forecasting using a hybrid model

Η πρόβλεψη των τιμών του πετρελαίου είναι ένα σημαντικό θέμα, λόγω της επίδρασής της σε πολλούς οικονομικούς και μη παράγοντες. Επειδή παράγοντες όπως η οικονομική ανάπτυξη, τα πολιτικά γεγονότα και οι ψυχολογικές προσδοκίες επηρεάζουν τις τιμές του πετρελαίου, η πρόβλεψη των τιμών του πετρελαίου έχει μεγάλη αβεβαιότητα. Δεν υπάρχει συναίνεση μεταξύ των ερευνητών σχετικά με τις τεχνικές και τα μοντέλα που χρησιμοποιούνται για την πρόβλεψη των τιμών του πετρελαίου. Ως εκ τούτου, θα πρέπει να αναπτυχθούν μέθοδοι πρόβλεψης με μεγαλύτερη ακρίβεια και μικρότερο σφάλμα. Είναι σημαντικό να συνδυάζονται διαφορετικά μοντέλα και να διερευνώνται διαφορετικές προσεγγίσεις, ειδικά μορφές που μεταβάλλονται χρονικά. Σε αυτή την έρευνα των Ali Safari & Maryam Davallou (2018), το Exponential Smoothing Model (ESM), το Autoregressive Integrated Moving Average Model (ARIMA) και το Nonlinear Autoregressive (NAR) Neural Network συνδυάζονται για να αυξηθεί η ακρίβεια της πρόβλεψης. Στο προτεινόμενο υβριδικό μοντέλο (PHM), τα χρονικά μεταβαλλόμενα βάρη για κάθε μοντέλο προσδιορίζονται από το φίλτρο Kalman.

Το PHM χρησιμοποιείται στις μηνιαίες τιμές του OPEC αργού πετρελαίου και στις τιμές του WTI αργού πετρελαίου. Για τις τιμές του OPEC αργού πετρελαίου χρησιμοποιούνται οι τιμές από τον Ιανουάριο του 2003 έως τον Σεπτέμβριο του 2016, ενώ ως σετ εκπαίδευσης χρησιμοποιήθηκαν το 80% και 90% των συνολικών 165 παρατηρήσεων και το υπόλοιπο 20% και 10% αντίστοιχα ως test set. Για τις τιμές του WTI αργού πετρελαίου χρησιμοποιούνται οι τιμές από τον Ιανουάριο του 1994 έως τον Ιούνιο του 2012. Το προτεινόμενο μοντέλο συγκρίθηκε με τα μοντέλα Equal Weights

Hybrid Model (EWH), Genetic Algorithm Weights Hybrid Model (GWM) και Zhang's hybrid model (ZHM) καθώς και με τα μοντέλα που το αποτελούν για να αξιολογηθεί η προβλεπτική του ικανότητα. Για την αξιολόγηση αυτή χρησιμοποιήθηκαν τα κριτήρια Root Mean Square Error (RMSE), Mean Absolute Percent Error (MAPE), Mean Absolute Error (MAE) και Directional Accuracy (DA).

Τα αριθμητικά αποτελέσματα δείχνουν μείωση του σφάλματος πρόβλεψης χρησιμοποιώντας το PHM σε σύγκριση με τα μοντέλα που το αποτελούν καθώς και από τα υπόλοιπα υβριδικά μοντέλα που συγκρίθηκε.

Forecasting Crude Oil Prices: a Deep Learning based Model

Με τη δημοτικότητα των Deep Learning μοντέλων στους τομείς της μηχανικής, έχει προσελκύσει σημαντικά ερευνητικά ενδιαφέροντα στον οικονομικό και χρηματοοικονομικό τομέα. Σε αυτό το άρθρο των Yanhui Chen et.al. (2017), χρησιμοποιείται ένα Deep Learning μοντέλο για να συλληφθούν τα άγνωστα μη γραμμικά χαρακτηριστικά που επηρεάζουν την τιμή του αργού πετρελαίου. Τα Deep Learning μοντέλα είναι ένα Deep Belief Network (DPN) και ένα Long Short Term Memory Network (LSTM) και συνδυάζονται με τα μοντέλα Random Walk και Autoregressive Moving Average (ARMA). Έτσι δημιουργούνται τα υβριδικά μοντέλα RW-DBN, ARMA-DBN, RW-LSTM, και ARMA-LSTM. Τα δεδομένα που χρησιμοποιήθηκαν αφορούσαν τις ημερήσιες τιμές του WTI αργού πετρελαίου για την περίοδο από 23 Ιουλίου 2007 έως 24 Φεβρουαρίου 2017. Για την εκπαίδευση του μοντέλου χρησιμοποιήθηκε το 70% των δεδομένων, ενώ το υπόλοιπο 30% χρησιμοποιήθηκε ως test set. Τα παραπάνω μοντέλα συγκρίθηκαν μεταξύ τους καθώς και με τα μοντέλα που τα αποτελούν για να αξιολογηθεί αν τα υβριδικά μοντέλα φέρουν βελτίωση στην πρόβλεψη έναντι των απλών. Για την αξιολόγηση αυτή χρησιμοποιήθηκε το κριτήριο Mean Square Error (MSE). Τα αποτελέσματα δείχνουν ότι κάθε υβριδικό μοντέλο επιτυγχάνει βελτιωμένη ακρίβεια πρόβλεψης. Αξίζει να σημειωθεί ότι τα υβριδικά μοντέλα που περιείχαν το DBN εμφάνιζαν μικρότερα σφάλματα από αυτά που περιείχαν το LSTM, ενώ το μοντέλο με την καλύτερη απόδοση από όλα τα άλλα ήταν το RW-DBN.

Seasonal learning based ARIMA algorithm for prediction of Brent oil Price trends

Η παγκόσμια οικονομία βασίζεται σε μεγάλο βαθμό στην παγκόσμια αγορά αργού πετρελαίου. Αυτή η έρευνα των Prasannavenkatesan Theerthagiri & A. Usha Ruby (2023) παρουσιάζει μια τεχνική πρόβλεψης της τιμής του αργού πετρελαίου χρησιμοποιώντας μια χρονικά μεταβαλλόμενη τάση. Λειτουργεί αποσυνθέτοντας τις μεταβολές της τιμής του αργού πετρελαίου με την πάροδο του χρόνου για να χαρακτηρίσει τις αλλαγές χρησιμοποιώντας ένα μεταβλητό χρονικό παράθυρο και να καθορίσει την μεταβολή της τιμής. Η μεθοδολογία Seasonal Auto Regressive

Integrated Moving Average (SARIMA) έχει αναπτυχθεί προκειμένου να προβλέψει τις διακυμάνσεις της τιμής του αργού πετρελαίου με την πάροδο του χρόνου. Το προτεινόμενο μοντέλο SARIMA προβλέπει τις τιμές χρησιμοποιώντας τη μέθοδο του σταθμισμένου μέσου όρου και τη μεθοδολογία εκτίμησης ακρίβειας με τη μέθοδο ανάλυσης σφαλμάτων ανάδρασης. Τα δεδομένα που χρησιμοποιήθηκαν αφορούσαν την ημερήσια τιμή του αργού πετρελαίου Brent, ενώ ο χρονικός ορίζοντας των δεδομένων φαίνεται να είναι από λίγο πριν το 1988 έως λίγο μετά το 2020 όπως παρουσιάζεται στα διαγράμματα. Το προτεινόμενο μοντέλο συγκρίθηκε με τα μοντέλα XGBoost Algorithm, Prophet Algorithm, ANN Algorithm, LSTM, Markov Regime Switching (MRS), Support Vector Regression (SVR), Feedforward Neural Network (FNN) και Stacked Denoising Auto-Encoder (SDAE) για να αξιολογηθεί η προβλεπτική του ικανότητα. Για την αξιολόγηση αυτή χρησιμοποιήθηκαν τα κριτήρια Root Mean Square Error (RMSE), Mean Absolute Error (MAE), Median Absolute Error (MedAE) και R-Squared (R^2). Τα αποτελέσματα της έρευνας δείχνουν ότι με την χρήση του SARIMA υπάρχει μεγάλη μείωση του σφάλματος της πρόβλεψης.

A New Approach for Forecasting Crude Oil Prices Based on Stochastic and Deterministic Influences of LMD Using ARIMA and LSTM Models

Το αργό πετρέλαιο είναι μια από τις μη ανανεώσιμες πηγές ενέργειας και είναι η ψυχή της σύγχρονης βιομηχανίας. Κάθε σημαντική αλλαγή στην τιμή του αργού πετρελαίου θα έχει επίδραση στον τρόπο με τον οποίο αναπτύσσεται η παγκόσμια οικονομία. Αυτή η μελέτη των Jawaria Nasir et.al. (2023) ανέπτυξε μια νέα τεχνική υβριδικής πρόβλεψης που εξαρτάται από την τοπική μέση αποσύνθεση, τα μοντέλα Autoregressive Integrated Moving Average (ARIMA) και Long Short-Short-Memory (LSTM) για την αύξηση της ακρίβειας πρόβλεψης της τιμής του αργού πετρελαίου. Τα αρχικά δεδομένα αποσυντίθενται με τοπική μέση αποσύνθεση (LMD) και τα αποσυντιθέμενα στοιχεία ανακατασκευάζονται σε στοχαστικά και ντετερμινιστικά (SD) στοιχεία για μείωση του κόστους υπολογισμού και ενίσχυση της ακρίβειας πρόβλεψης. Το προτεινόμενο υβριδικό μοντέλο LMD-SD-ARIMA-LSTM μείωσε την αστάθεια και έλυσε το πρόβλημα της υπερπροσαρμογής των νευρωνικών δικτύων.

Τα δεδομένα που χρησιμοποιήθηκαν αφορούσαν τις ημερήσιες τιμές του WTI αργού πετρελαίου για την περίοδο από 12 Μαρτίου 2018 έως 14 Φεβρουαρίου 2022 (999 παρατηρήσεις). Για την εκπαίδευση του μοντέλου χρησιμοποιήθηκε το 75% των αρχικών δεδομένων ενώ το υπόλοιπο 25% χρησιμοποιήθηκε ως test set. Το προτεινόμενο μοντέλο συγκρίθηκε με τα μοντέλα ARIMA, LSTM, LMD-ARIMA, LMD-SD-ARIMA, LMD-ARIMA-LSTM και Naive, για να αξιολογηθεί η προβλεπτική του ικανότητα. Για την αξιολόγηση αυτή χρησιμοποιήθηκαν τα κριτήρια Root Mean Square Error (RMSE), Mean Absolute Percent Error (MAPE) και Mean Absolute Error (MAE). Τα αποτελέσματα της έρευνας δείχνουν ότι το προτεινόμενο μοντέλο φέρει καλύτερη πρόβλεψη καθώς έχει τις μικρότερες τιμές σφαλμάτων από όλα τα συγκρινόμενα μοντέλα.

An Ensemble LGBM (Light Gradient Boosting Machine) Approach for Crude Oil Price Prediction

Το αργό πετρέλαιο θεωρείται ένας από τους σημαντικότερους πόρους στον κόσμο σήμερα. Το μεγαλύτερο μέρος των καυσίμων που χρησιμοποιούνται σήμερα είναι διυλισμένο από αργό πετρέλαιο. Τα καύσιμα έχουν επίσης μεγάλο αντίκτυπο στην παγκόσμια οικονομία. Η αγορά αργού πετρελαίου είναι ρευστή και αβέβαιη ενώ η πρόβλεψη της τιμής της αγοράς αργού πετρελαίου έχει γίνει μια αναγκαιότητα κάθε κυβέρνησης, βιομηχανίας και ιδιώτη. Η πρόβλεψη της τιμής του αργού πετρελαίου μπορεί να βοηθήσει στην επίτευξη μιας βιώσιμης οικονομίας. Ο στόχος αυτής της μελέτης των Sad Wadi Sajid et.al. (2023) είναι να προβλέψει τις τιμές αυτές στην αγορά όσο το δυνατόν ακριβέστερα χρησιμοποιώντας μεθοδολογία machine learning και ensemble learning. Επομένως προτείνεται για την πρόβλεψη αυτή η χρήση των αλγορίθμων Light Gradient Boosting (LGBM), Random Forest Ensemble Machine Learning, Lasso Regression και Decision Tree Machine Learning Algorithm. Τα δεδομένα που χρησιμοποιήθηκαν αφορούσαν τις ημερήσιες τιμές του Brent αργού πετρελαίου για την περίοδο από 20 Μαΐου 1987 έως 10 Σεπτεμβρίου 2021(8954 παρατηρήσεις). Τα τέσσερα μοντέλα που αναφέρθηκαν παραπάνω συγκρίθηκαν μεταξύ τους για να αξιολογηθεί η προβλεπτική τους ικανότητα. Για την αξιολόγηση αυτή χρησιμοποιήθηκαν τα κριτήρια Root Mean Square Error (RMSE), Mean Absolute Percent Error (MAPE), Mean Absolute Error (MAE) και Mean Square Error (MSE). Από τα αποτελέσματα της έρευνας το μοντέλο LGBM παρουσίασε την καλύτερη πρόβλεψη καθώς είχε τα μικρότερα σφάλματα. Αξίζει όμως να σημειωθεί ότι και τα υπόλοιπα μοντέλα είχαν αρκετά μικρές τιμές σφαλμάτων, πράγμα που τα καθιστά και αυτά κατάλληλα για την πρόβλεψη του αργού πετρελαίου.

Predicting Natural Gas Prices Based on a Novel Hybrid Model with Variational Mode Decomposition

Το φυσικό αέριο έχει κρίσιμο ρόλο στη μετάβαση ενεργειακών συστημάτων χαμηλών εκπομπών άνθρακα και την ενεργειακή ασφάλεια της χώρας. Η ακριβής και αξιόπιστη πρόβλεψη της τιμής του φυσικού αερίου μπορεί να θεωρηθεί σημαντικό ζήτημα τόσο για τους συνδεδεμένους επενδυτές όσο και για τις κυβερνήσεις. Αυτή η μελέτη των Qin Lu et.al. (2023) υιοθετεί ένα μοντέλο Decomposition-Ensemble για να βελτιώσει την ακρίβεια της πρόβλεψης της τιμής του φυσικού αερίου. Η διαδικασία έχει ως εξής: Πρώτον, η αρχική ακολουθία τιμών ενέργειας αποσυντίθεται σε υποακολουθίες με διαφορετικές συχνότητες μέσω Variational Mode Decomposition (VMD) με γενετικό αλγόριθμο. Δεύτερον, το νευρωνικό δίκτυο Elman (ELMAN) προβλέπει την τελευταία υποακολουθία υψηλής συχνότητας και το νευρωνικό δίκτυο Bidirectional Gated Recurrent Unit (BiGRU) προβλέπει άλλες υποακολουθίες. Τρίτον, η τελική πρόβλεψη των υποακολουθιών με διάφορα μοντέλα ενσωματώνεται με προσέγγιση μη γραμμικής ολοκλήρωσης.

Τα δεδομένα που χρησιμοποιήθηκαν αφορούσαν την ημερήσια τιμή των futures τόσο για το Henry Hub φυσικό αέριο όσο και για το UK φυσικό αέριο, καθώς και την τιμή

του Henry Hub φυσικού αερίου. Τα δεδομένα χωρίστηκαν σε τρία διαφορετικά cases (Case 1, Case 2, Case 3) ώστε να γίνουν τρεις διαφορετικές προβλέψεις, μία για κάθε case, όμως όλα αφορούσαν την περίοδο από 3 Δεκεμβρίου 2007 έως 30 Ιουνίου 2022. Για την εκπαίδευση του μοντέλου χρησιμοποιήθηκε το 60% των αρχικών δεδομένων ενώ το υπόλοιπο 40% χρησιμοποιήθηκε σαν test set.

Το προτεινόμενο μοντέλο συγκρίθηκε με τα μοντέλα Multilayer Perceptron (MLP), Gated Recurrent Unit (GRU), Long Short-term Memory Network (LSTM), BiGRU, ELMAN, Bidirectional Long Short-term Memory Network (BiLSTM), Support Vector Regression (SVR), τους συνδυασμούς τους με το VMD καθώς και με τα μοντέλα VMD-BiGRU-ELMAN, VMD-BiLSTM-ELMAN, VMD-BiGRU-MLP και VMD-BiLSTM-SVR για να αξιολογηθεί η προβλεπτική του ικανότητα. Για την αξιολόγηση αυτή χρησιμοποιήθηκαν τα κριτήρια Root Mean Square Error (RMSE), Mean Absolute Error (MAE), Mean Absolute Percentage Error (MAPE) και R-Squared (R^2).

Τα αποτελέσματα της έρευνας δείχνουν ότι το προτεινόμενο μοντέλο παρουσιάζει καλύτερη προβλεπτική ικανότητα από τα υπόλοιπα μοντέλα και για τα τρία Cases καθώς έχει τις μικρότερες τιμές σφαλμάτων. Άρα φαίνεται ότι το προτεινόμενο μοντέλο είναι κατάλληλο για την πρόβλεψη τόσο των τιμών όσο και των τιμών των futures του Φυσικού Αερίου.

Monthly crude oil spot price forecasting using variational mode decomposition

Το αργό πετρέλαιο είναι ένα από τα σημαντικότερα εμπορικά εμπορεύματα στον κόσμο και οι διακυμάνσεις των τιμών του έχουν σημαντικές επιπτώσεις στις παγκόσμιες οικονομικές δραστηριότητες. Σε αυτή την έρευνα των Jinchao Li et.al. (2019), προτείνονται υβριδικά μοντέλα για την μηνιαία πρόβλεψη της τιμής του αργού πετρελαίου χρησιμοποιώντας τεχνικές Variational Mode Decomposition και τεχνητής νοημοσύνης. Πιο αναλυτικά χρησιμοποιούνται τα μοντέλα Support Vector Machine Optimized by Genetic Algorithm (GASVM) και Back Propagation Neural Network Optimized by Genetic Algorithm (GABP). Επιπλέον, διερευνώνται και λαμβάνονται υπόψη παράγοντες που επηρεάζουν τη μακροπρόθεσμη τιμή του αργού πετρελαίου, όπως η παγκόσμια παραγωγή αργού πετρελαίου καθώς και η οικονομική δραστηριότητα (ο Βιομηχανικός Δείκτης Dow Jones) στην πρόβλεψη της τιμής του αργού πετρελαίου. Δηλαδή για τα μοντέλα VMD-GASVM και VMD-BPNN δημιουργούνται τρεις παραλλαγές όπου η πρώτη λαμβάνει υπόψη μόνο την τιμή του αργού πετρελαίου, η δεύτερη λαμβάνει υπόψη και την παγκόσμια παραγωγή αργού πετρελαίου ενώ η τρίτη λαμβάνει υπόψη όλα τα παραπάνω καθώς και τον βιομηχανικό δείκτη Dow Jones.

Τα δεδομένα που χρησιμοποιήθηκαν αφορούσαν την τιμή του WTI και Brent αργού πετρελαίου καθώς και μηνιαία δεδομένα για την παγκόσμια παραγωγή αργού πετρελαίου και δεδομένα για τον δείκτη Dow Jones Industrial Average. Τα δεδομένα αφορούσαν την περίοδο από τον Ιανουάριο του 1994 έως τον Ιούλιο του 2018 (295 παρατηρήσεις).

Οι παραπάνω παραλλαγές των μοντέλων συγκρίθηκαν με τα μοντέλα VMD-ARIMA, EEMD-GASVM, EEMD-GABP, EEMD-ARIMA, GA-SVM, GA-BPNN και ARIMA (EEMD = Ensemble Empirical Mode Decomposition) για να αξιολογηθεί η προβλεπτική τους ικανότητα. Για την αξιολόγηση αυτή χρησιμοποιήθηκαν τα κριτήρια Root Mean Square Error (RMSE), Mean Absolute Percent Error (MAPE) και Directional Statistics (Dstat).

Τα αποτελέσματα της έρευνας δείχνουν ότι τα μοντέλα περιείχαν την τεχνική VMD παρουσίαζαν καλύτερη προβλεπτική ικανότητα από αυτά που χρησιμοποιούσαν την τεχνική EEMD. Επίσης τα μοντέλα που λάμβαναν υπόψη τους άλλους δύο παράγοντες φαίνεται να βελτίωναν αρκετά τις προβλέψεις τους.

Forecasting crude oil price with an EMD-based neural network ensemble learning paradigm

Σε αυτή την έρευνα των Lean Yu et.al. (2008), προτείνεται ένα παράδειγμα Ensemble Learning Νευρωνικό δίκτυο βασισμένο σε Empirical Mode Decomposition (EMD) για την πρόβλεψη των τιμών του αργού πετρελαίου. Για το σκοπό αυτό, οι αρχικές σειρές τιμών αργού πετρελαίου αρχικά αποσυντέθηκαν σε έναν πεπερασμένο και συχνά μικρό αριθμό Intrinsic Mode Functions (IMFs). Στη συνέχεια χρησιμοποιήθηκε ένα Feed-Forward Neural Network (FNN) με τρία επίπεδα για τη μοντελοποίηση καθενός από τα εξαγόμενα IMFs, έτσι ώστε οι τάσεις αυτών να μπορούν να προβλεφθούν με ακρίβεια. Τέλος, τα αποτελέσματα πρόβλεψης όλων των IMFs συνδυάζονται με ένα Adaptive Linear Neural Network (ALNN), για να διαμορφωθεί ένα συνολικό αποτέλεσμα για την αρχική σειρά τιμών αργού πετρελαίου.

Τα δεδομένα που χρησιμοποιήθηκαν αφορούσαν τις τιμές του WTI και Brent αργού πετρελαίου για την περίοδο από 1 Ιανουαρίου 1986 έως 30 Σεπτεμβρίου 2006 (5237 παρατηρήσεις) και για την περίοδο από 20 Μάιου 1987 έως 30 Σεπτεμβρίου 2006 (4933 παρατηρήσεις) αντίστοιχα. Για την εκπαίδευση του μοντέλου με βάση το WTI αργό πετρέλαιο χρησιμοποιήθηκαν 3800 παρατηρήσεις ενώ οι υπόλοιπες 1437 χρησιμοποιήθηκαν ως test set. Ενώ για την εκπαίδευση του μοντέλου με βάση το Brent αργό πετρέλαιο χρησιμοποιήθηκαν 3965 παρατηρήσεις και οι υπόλοιπες 968 χρησιμοποιήθηκαν ως test set.

Το προτεινόμενο μοντέλο συγκρίθηκε με τα μοντέλα EMD-FNN-Averaging, EMD-ARIMA-ALNN, EMD-ARIMA-Averaging, Single FNN και Single ARIMA για να αξιολογηθεί η προβλεπτική του ικανότητα. Για την αξιολόγηση αυτή χρησιμοποιήθηκαν τα κριτήρια Root Mean Square Error (RMSE) και Directional Statistics (Dstat).

Από τα αποτελέσματα της έρευνας φαίνεται ότι το προτεινόμενο μοντέλο αποδίδει καλύτερα από τα υπόλοιπα καθώς την μικρότερη τιμή σφάλματος στο RMSE και την μεγαλύτερη τιμή στο Dstat και για τις δύο περιπτώσεις αργού πετρελαίου. Επομένως το μοντέλο αυτό φαίνεται να είναι μία πολύ υποσχόμενη τεχνική πρόβλεψης της τιμής του αργού πετρελαίου.

A multi-scale model with feature recognition for the use of energy futures price forecasting

Η προσπάθεια τιμολόγησης των futures της ενέργειας είναι μια δύσκολη υπόθεση όσον αφορά την τάση της παγκόσμιας οικονομίας, η απότομη διακύμανση της οποίας αυξάνει την πολυπλοκότητα της ανάλυσης τέτοιων τιμών. Η πλειονότητα των προηγούμενων ερευνών έχει επικεντρωθεί στην ενοποίηση μοντέλων, σε παράγοντες που βασίζονται σε δεδομένα και στη βελτιστοποίηση πληροφοριών. Ωστόσο, δεν είναι ακόμα εύκολο να παρέχουμε ένα ισχυρό μοντέλο για την κατανόηση της τάσης των τιμών των futures της ενέργειας λόγω της πολύπλευρης φύσης των χρηματοπιστωτικών αγορών. Για να είναι εφικτή η πρόβλεψη των futures της ενέργειας, προτείνεται ένα μοντέλο, από τους Ranran Li & Xiao Song (2023), πολλαπλών κλιμάκων που ενσωματώνει την προσέγγιση Decomposition-Ensemble και τη μέθοδο Subcomponents Clustering, η οποία ξεπερνά το πρόβλημα της διακύμανσης της τιμής των futures της ενέργειας. Η μέθοδος Subcomponents Clustering χρησιμοποιείται για την απόκτηση ενός αριθμού υποσειρών με διαφορετικές συχνότητες μετά την αποσύνθεση της σειράς τιμών futures της ενέργειας σε πολλά υποσυστατικά. Στη συνέχεια, το γραμμικό μοντέλο χρησιμοποιείται για την πρόβλεψη της συνιστώσας τάσης, ενώ ταυτόχρονα το μοντέλο μηχανικής μάθησης προβλέπει τη μη γραμμικότητα. Επομένως τα μοντέλα που δημιουργήθηκαν από την παραπάνω σύνθεση ήταν τα VMD-SVM-ARMA, VMD-LSSVM-ARMA και CEEMDan-SVM-ARMA (Όπου VMD = Variational Mode Decomposition, CEEMDan = Complete Ensemble Empirical Mode Decomposition with Adaptive Noise, SVM = Support Vector Machine, LSSVM = Least-Squares Support Vector Machine, ARMA = Autoregressive Moving Average). Τα μοντέλα αυτά συγκρίθηκαν με τα αντίστοιχα απλά μοντέλα που τα αποτελούν καθώς και με συνδυασμούς αυτών των απλών με τις μεθόδους decomposition. Τα δεδομένα που χρησιμοποιήθηκαν αφορούσαν την ημερήσια τιμή των futures για το αργό πετρέλαιο και το φυσικό αέριο για την περίοδο από 1 Ιανουαρίου 2017 έως 28 Φεβρουαρίου 2020.

Για την αξιολόγηση της παραπάνω σύγκρισης των μοντέλων χρησιμοποιήθηκαν τα κριτήρια Mean Square Error (MSE), Symmetric Mean Absolute Percent Error (sMAPE), Standard Deviation of Error (SDE) και Mean Absolute Scaled Error (MASE). Από τα αποτελέσματα της έρευνας φαίνεται ότι τα μοντέλα που χρησιμοποιούσαν την παραπάνω σύνθεση παρουσιάζουν καλύτερη προβλεπτική ικανότητα. Επίσης τα μοντέλα που περιείχαν την μέθοδο VMD παρουσίαζαν καλύτερα αποτελέσματα σε σχέση με αυτά που περιείχαν την CEEMDan, ενώ το μοντέλο που παρουσίαζε την καλύτερη πρόβλεψη ήταν το VMD-SVM-ARMA.

3.Θεωρητική Προσέγγιση

3.1 Ασαφής Λογική

3.1.1 Εισαγωγή

Η ασαφής λογική είναι μια μορφή λογικής πολλών τιμών στην οποία η τιμή αληθείας των μεταβλητών μπορεί να είναι οποιοσδήποτε πραγματικός αριθμός μεταξύ 0 και 1. Χρησιμοποιείται για να χειριστεί την έννοια της μερικής αλήθειας, όπου η τιμή αληθείας μπορεί να κυμαίνεται μεταξύ εντελώς αληθούς και εντελώς ψευδούς.

Αντίθετα, στη Boolean λογική, οι τιμές αλήθειας των μεταβλητών μπορεί να είναι μόνο οι ακέραιες τιμές 0 ή 1. Ο όρος ασαφής λογική εισήχθη με την πρόταση της θεωρίας ασαφών συνόλων (fuzzy set theory) το 1965 από τον Ιρανό-Αζερμπαϊτζανό μαθηματικό Lotfi Zadeh. Η ασαφής λογική είχε, ωστόσο, μελετηθεί από τη δεκαετία του 1920, ως λογική άπειρων τιμών, ιδιαίτερα από τους Łukasiewicz και Tarski.

Η ασαφής λογική βασίζεται στην παρατήρηση ότι οι άνθρωποι λαμβάνουν αποφάσεις με βάση ανακριβείς και μη αριθμητικές πληροφορίες. Τα ασαφή μοντέλα ή τα ασαφή σύνολα είναι μαθηματικά μέσα για την αναπαράσταση της ασάφειας και των ανακριβών πληροφοριών (εξού και ο όρος ασαφής). Αυτά τα μοντέλα έχουν την ικανότητα αναγνώρισης, αναπαράστασης, χειρισμού, ερμηνείας και χρήσης δεδομένων και πληροφοριών που είναι ασαφή και στερούνται βεβαιότητας. Η ασαφής λογική έχει εφαρμοστεί σε πολλά πεδία, από τη θεωρία ελέγχου έως την τεχνητή νοημοσύνη.

3.1.2 Ασαφή Σύνολα

Έστω X ένα ευρύτερο σύνολο αναφοράς με επί μέρους στοιχεία x , δηλαδή $X = \{x\}$. Ένα ασαφές σύνολο (fuzzy set) A του υπερσυνόλου αναφοράς X μπορεί να εκφραστεί συμβολικά ως ένα σύνολο διατεταγμένων ζευγών (ordered pairs):

$$A = \int_X \mu_A(x)/x \text{ για συνεχείς τιμές του συνόλου } X, \text{ και} \quad (1)$$

$$A = \sum_{i=1}^N \mu_A(x_i)/x_i \text{ για διακριτές τιμές του συνόλου } X. \quad (2)$$

Η τιμή $\mu_A(x)$ λέγεται βαθμός αληθείας και συμβολίζει το βαθμό συγγένειας του x στο A και παίρνει τιμές στο διάστημα $[0,1]$. Η συνάρτηση μ_A ονομάζεται συνάρτηση συμμετοχής ή συγγένειας (membership function) και υποδεικνύει το βαθμό κατά τον οποίον το σύνολο x ανήκει στο σύνολο A , δηλαδή

$$\mu_A(x): X \rightarrow [0,1] \quad (3)$$

3.1.3 Συναρτήσεις Συμμετοχής

Όπως αναφέρθηκε παραπάνω η συνάρτηση συμμετοχής υποδεικνύει τον βαθμό κατά τον οποίο κάθε στοιχείο x ανήκει στο υπό μελέτη σύνολο A και συμβολίζεται με μ_A . Κατά τη σχεδίασή τους, οι συναρτήσεις συμμετοχής μπορεί να λάβουν διάφορα σχήματα και να χρησιμοποιούν διαφορετικές παραμέτρους. Παρακάτω είναι μερικά παραδείγματα μορφών μονοδιάστατων συναρτήσεων συμμετοχής.

Τραπεζοειδής συνάρτησης συμμετοχής


Η τραπεζοειδής συνάρτηση συμμετοχής (trapezoidal membership function, trap_MF) αποτελεί μία τμηματικά γραμμική συνάρτηση (piecewise-linear function). Περιγράφεται από μία τετράδα παραμέτρων $\{a,b,c,d\}$, οι οποίες καθορίζουν τις συντεταγμένες των τεσσάρων κορυφών του τραπεζίου και όπου για αυτές ισχύει $a < b < c < d$.

$$MF(x;a,b,c,d) = \begin{cases} 0, & x < a \\ \frac{x-a}{b-a}, & a \leq x < b \\ 1, & b \leq x < c \\ \frac{d-x}{d-c}, & c \leq x < d \\ 0, & d \leq x \end{cases} \quad (4)$$

Επίσης η γενική συνάρτηση της τραπεζοειδούς μπορεί να γραφτεί ως εξής.

$$MF(x;a,b,c,d) = \max \left\{ \min \left(\frac{x-a}{b-a}, 1, \frac{d-x}{d-c} \right), 0 \right\} \quad (5)$$

Στο σχήμα 3.1 παρουσιάζεται η γραφική απεικόνισή της, όπου οι παράμετροι λαμβάνουν τις τιμές $\{a,b,c,d\} = \{10,20,40,70\}$.



Σχήμα 3.1 Τραπεζοειδής συνάρτηση συμμετοχής

Τριγωνική Συνάρτηση συμμετοχής


Η τριγωνική συνάρτηση συμμετοχής (triangular membership function, tri_MF) προέρχεται από την τραπεζοειδή συνάρτηση συμμετοχής, εάν $b = c$, δηλαδή εάν εξαλειφθεί ο οριζόντιος κλάδος. Περιγράφεται από μία τριάδα παραμέτρων $\{a,b,c\}$, οι οποίες παρέχουν τις συντεταγμένες των τριών κορυφών του τριγώνου και για αυτές ισχύει $a < b < c$.

$$MF(x,a,b,c) = \begin{cases} 0, & x < a \\ \frac{x-a}{b-a}, & a \leq x < b \\ \frac{c-x}{c-b}, & b \leq x < c \\ 0, & c \leq x \end{cases} \quad (6)$$

Επίσης η γενική συνάρτηση της τριγωνικής μπορεί να γραφτεί ως εξής.

$$MF(x,a,b,c) = \max \left\{ \min \left(\frac{x-a}{b-a}, \frac{c-x}{c-b} \right), 0 \right\} \quad (7)$$

Στο σχήμα 3.2 παρουσιάζεται η γραφική απεικόνισή της, όπου οι παράμετροι λαμβάνουν τις τιμές $\{a,b,c\} = \{10,50,70\}$.




Σχήμα 3.2 Τριγωνική συνάρτηση συμμετοχής

Γενικευμένη καμπανοειδής συνάρτηση συμμετοχής

Η γενικευμένη καμπανοειδής ή κωδωνοειδής συνάρτηση συμμετοχής (generalized bell-shaped membership function, bell_MF) παραμετροποιείται από τρεις παραμέτρους $\{a,b,c\}$ και έχει την ακόλουθη μορφή:

$$MF(x;a,b,c) = \frac{1}{1 + \left(\frac{x-c}{a}\right)^{2b}} \quad (8)$$

Στο σχήμα 3.3 παρουσιάζεται η γραφική απεικόνισή της, όπου οι παράμετροι λαμβάνουν τις τιμές $\{a,b,c\}=\{20,4,60\}$.




Σχήμα 3.3 Καμπανοειδής συνάρτηση συμμετοχής

Γκαουσιανή συνάρτηση συμμετοχής

Η γκαουσιανή συνάρτηση συμμετοχής (Gaussian membership function, gauss_MF) έχει δύο παραμέτρους $\{m,\sigma\}$ και περιγράφεται από τη συνάρτηση:

$$MF(x;m,\sigma) = e^{-\frac{1}{2}\left(\frac{x-m}{\sigma}\right)^2} \quad (9)$$

Στο σχήμα 3.4 παρουσιάζεται η γραφική απεικόνισή της, όπου οι παράμετροι λαμβάνουν τις τιμές $\{m,\sigma\}=\{60,10\}$.




Σχήμα 3.4 Γκαουσιανή συνάρτηση συμμετοχής

Σιγμοειδής Συνάρτηση Συμμετοχής

Η σιγμοειδής συνάρτηση συμμετοχής διαθέτει δύο παραμέτρους $\{a, c\}$ και υλοποιείται από την ακόλουθη μαθηματική έκφραση.

$$MF(x; a, c) = \frac{1}{1 + \exp(-a(x - c))} \quad (10)$$

Στο σχήμα 3.5 παρουσιάζεται η γραφική απεικόνισή της, όπου $c=60$. Η παράμετρος a λαμβάνει θετικές και αρνητικές τιμές.



Σχήμα 3.5 Σιγμοειδής συνάρτηση συμμετοχής

3.1.4 Ασαφή σύνολα – ιδιότητες και χαρακτηριστικά

Σύνολο υποστήριξης

Το σύνολο υποστήριξης ή ενεργός περιοχή ή στήριγμα ή φορέας (support) ενός ασαφούς συνόλου A είναι ένα κλασσικό (σαφές) σύνολο, το οποίο περιέχει όλα τα στοιχεία x του X για τα οποία ισχύει $\mu_A(x) > 0$.

$$\text{Support}(A) = \{x \in X \mid \mu_A(x) > 0\} \quad (11)$$

Ύψος

Το ύψος (height) ενός ασαφούς συνόλου A είναι η μέγιστη τιμή της συνάρτησης συμμετοχής $\mu_A(x)$ στο δεδομένο πεδίο ορισμού X

$$\text{Height}(A) = \sup(\mu_A(x)) = \max(\mu_A(x)), \text{ για κάθε } x \in X. \quad (12)$$

Κανονικό ασαφές σύνολο

Ένα ασαφές σύνολο καλείται κανονικό ή κανονικοποιημένο (normal – normalized fuzzy set) εάν το ύψος του είναι μονάδα, δηλαδή, $\text{Height}(A) = 1$. Εάν το ύψος είναι μικρότερο της μονάδας, το ασαφές σύνολο καλείται υποκανονικό (subnormal).

Πυρήνας

Ο πυρήνας ή κόρος (core ή kernel) ενός ασαφούς συνόλου A είναι ένα κλασσικό (σαφές) σύνολο, το οποίο περιέχει όλα τα στοιχεία x του X για τα οποία ισχύει

$$\mu_A(x) = 1.$$

Τα κανονικά ασαφή σύνολα έχουν κόρο ένα μη κενό σύνολο. Δηλαδή, υπάρχει τουλάχιστον μία τιμή του x για την οποία ισχύει $\mu_A(x) = 1$.

Σημείο καμψής

Ένα σημείο x του πεδίου ορισμού X καλείται σημείο καμψής (crossover point) εφόσον η τιμή της συνάρτησης συμμετοχής στο σημείο αυτό έχει τιμή 0.5.

$$\text{Crossover}(A) = \{x \in X \mid \mu_A(x) = 0.5\} \quad (13).$$

Συμμετρικό ασαφές σύνολο

Ένα ασαφές σύνολο A είναι συμμετρικό εάν η συνάρτηση συμμετοχής του $\mu_A(x)$ είναι συμμετρική γύρω από μια τιμή $x=c$.

$$\mu_A(c+x) = \mu_A(c-x) \text{ για κάθε } x \in X. \quad (14)$$

Σύνολο διατομής -α

Το σύνολο διατομής-α (α-cut set) ενός ασαφούς συνόλου συμβολίζεται με A_α και είναι ένα κλασσικό (σαφές) σύνολο, το οποίο περιέχει όλα τα στοιχεία του πεδίου ορισμού για τα οποία ισχύει ότι :

$$\mu_A(x) \geq \alpha \text{ με } 0 < \alpha \leq 1 \quad (15)$$

Ένα ασθενές σύνολο διατομής (α-cut set) καθορίζεται από την ύπαρξη της ισότητας στην ανίσωση όπως φαίνεται παρακάτω.

$$A_\alpha = \{ x \in X \mid \mu_A(x) \geq \alpha \} \quad (16)$$

Επομένως, ένα ισχυρό σύνολο διατομής (strong α-cut set) ορίζεται ως ακολούθως.

$$A_{\alpha+} = \{ x \in X \mid \mu_A(x) > \alpha \} \quad (17)$$

Σύμφωνα με τις προηγούμενες ιδιότητες ο πυρήνας και το σύνολο υποστήριξης είναι διαδοχικά σύνολα διατομής -α.

$$\text{Supp}(A) = A_{\alpha+} \quad (18)$$

$$\text{Core}(A) = A_\alpha \quad (19)$$

Κυρτό ασαφές σύνολο


Ένα ασαφές σύνολο A καλείται κυρτό (convex) εάν και μόνο εάν για κάθε ζεύγος τιμών x_1, x_2 του πεδίου ορισμού και για κάθε $\lambda \in [0,1]$, ισχύει η σχέση:

$$\mu_A(\lambda * x_1 + (1-\lambda) * x_2) \geq \min (\mu_A(x_1), \mu_A(x_2)) \quad (20)$$

Ισοδύναμα, ένα ασαφές σύνολο A είναι κυρτό όταν όλα τα σύνολα διατομής-α είναι κυρτά σύνολα. Σε αντίθετη περίπτωση, το A καλείται μη κυρτό.

Η κυρτότητα ενός ασαφούς συνόλου A συνεπάγεται ότι η συνάρτηση συμμετοχής του δεν παρουσιάζει ανεβοκατεβάσματα. Με άλλα λόγια, αρχικά ακολουθεί μια ανοδική πορεία μέχρι τον μέγιστο βαθμό συμμετοχής και στη συνέχεια ακολουθεί μια μονότονα φθίνουσα πορεία έως ότου μηδενισθεί.

Στο σχήμα 3.6 φαίνεται η σύγκριση ανάμεσα σε κυρτά και μη κυρτά ασαφή σύνολα.




Σχήμα 3.6 Κυρτά και μη κυρτά ασαφή σύνολα

Ασαφές singleton

Το ασαφές singleton (fuzzy singleton) είναι ένα εκφυλισμένο ασαφές σύνολο, υπό την έννοια ότι αποτελείται από ένα στοιχείο με βαθμό συμμετοχής 1, ενώ όλα τα υπόλοιπα στοιχεία του πεδίου ορισμού έχουν τιμή 0.

$$\mu_A(x) = \begin{cases} 1, & x = x_0 \\ 0, & x \neq x_0, x \in U \end{cases} \quad (21)$$

Αποτελεί χρήσιμο εφεύρημα καθώς, επιτρέπει την ασαφοποίηση των δεδομένων εισόδου σε ένα ασαφές σύστημα.



Σχήμα 3.7 Ασαφές singleton

3.1.5 Λογικές πράξεις μεταξύ ασαφών συνόλων

Τομή ασαφών συνόλων

Η τομή (intersection) δύο ασαφών συνόλων A και B, που ορίζονται στο ίδιο πεδίο ορισμού X, είναι ένα ασαφές σύνολο C, το οποίο συμβολίζεται με την σχέση

$$C = A \cap B .$$

Η σχέση αυτή ισοδυναμεί με την έκφραση ότι το C = A και B.

Η συνάρτηση συμμετοχής του C προκύπτει από τις συναρτήσεις συμμετοχής των A και B με χρήση του τελεστή τομής:

$$\mu_C(x) = \mu_A(x) \wedge \mu_B(x) \Leftrightarrow \min(\mu_A(x), \mu_B(x)) \text{ για κάθε } x \in X \quad (22)$$

Ένωση ασαφών συνόλων

Η ένωση δύο ασαφών συνόλων A και B (union), που ορίζονται στο ίδιο πεδίο ορισμού X, είναι ένα ασαφές σύνολο C, το οποίο συμβολίζεται με την σχέση

$$C = A \cup B.$$

Η σχέση αυτή ισοδυναμεί με την έκφραση $C = A \text{ ή } B$.

Η συνάρτηση συμμετοχής του C προκύπτει από τις συναρτήσεις συμμετοχής των A και B με χρήση του τελεστή ένωσης:

$$\mu_C(x) = \mu_A(x) \vee \mu_B(x) \Leftrightarrow \max(\mu_A(x), \mu_B(x)) \text{ για κάθε } x \in X \quad (23)$$

Συμπλήρωμα ασαφούς συνόλου

Το συμπλήρωμα (complement) ενός ασαφούς συνόλου A είναι ένα ασαφές σύνολο, το οποίο συμβολίζεται ως \bar{A} και έχει την ακόλουθη συνάρτηση συμμετοχής:

$$\mu_{\bar{A}}(x) = 1 - \mu_A(x), \text{ για κάθε } x \in X \quad (24)$$

Η έννοια του συμπληρώματος στα ασαφή σύνολα σχετίζεται με εκείνη της άρνησης, δηλαδή η παραπάνω σχέση θα μπορούσε να ερμηνευτεί ως όχι A.

Ασαφές υποσύνολο

Ένα ασαφές σύνολο A ονομάζεται γνήσιο υποσύνολο ενός ασαφούς συνόλου B, όταν η συνάρτηση συμμετοχής του A είναι μικρότερη με την αντίστοιχη του B, για κάθε $x \in X$.

$$\mu_A(x) < \mu_B(x) \quad (25)$$

Με ανάλογο τρόπο, ασαφές σύνολο A είναι υποσύνολο του B εάν $\mu_A(x) \leq \mu_B(x)$.

3.1.6 Ασαφείς κανόνες

Εννοιολογικά, ο ασαφής κανόνας είναι ένας μηχανισμός αναπαράστασης της γνώσης, ο οποίος προσιδιάζει στον ανθρώπινο τρόπο σκέψης. Τα ασαφή σύνολα που εκφράζουν λεκτικούς όρους συνδυάζονται μεταξύ τους και δημιουργούν ασαφείς κανόνες που αναπαριστούν τη γνώση που έχουμε για το σύστημα. Ένας ασαφής κανόνας αποτελείται από δύο βασικά μέρη α) το τμήμα υπόθεσης (premise part) και β) το τμήμα απόδοσης ή απόφασης (consequent part). Ένας απλός κανόνας είναι της μορφής:

If x is A then y is B


Το τμήμα if x is A είναι το τμήμα υπόθεσης και το τμήμα then y is B το τμήμα απόφασης ή συμπεράσματος, όπου A και B ασαφή σύνολα.

Κατά την υλοποίηση των ασαφών κανόνων υπάρχει η δυνατότητα διαφορετικές γλωσσικές μεταβλητές να συνδυαστούν μεταξύ τους στο πεδίο της υπόθεσης, με το συνδετικό "και" (and) ή το συνδετικό "ή" (or). Κατά την διαδικασία της υπόθεσης οι μεταβλητές αυτές θα αποτελέσουν τις εισόδους στο σύστημα ενώ το συμπέρασμα της υπόθεσης θα είναι η έξοδος. Με αυτόν τον τρόπο επιτυγχάνεται παράλληλη επεξεργασία νοηματικά διαφορετικών παραγόντων, για την εξαγωγή ενός συμπεράσματος.

3.1.7 Ασαφή συστήματα

Η διαδικασία η οποία ενσωματώνει ένα σύνολο ασαφών κανόνων if – then, με τις συναρτήσεις συμμετοχής και τους μηχανισμούς εξαγωγής συμπερασμάτων, συνθέτουν όλες τις παραμέτρους ενός συστήματος ασαφούς συμπερασμού. Τα ασαφή συστήματα περιλαμβάνουν κάθε δυνατότητα εξαγωγής συμπερασμάτων ή αποφάσεων, υπό συνθήκες αβεβαιότητας και ανήκουν στην κατηγορία των ευφύων συστημάτων ανάλυσης. Σύμφωνα με τα παραπάνω ένα ασαφές σύστημα με βάση την αρχιτεκτονική του αποτελείται από τους εξής παράγοντες:

1. Βάση γνώσης (knowledge base).
2. Ασαφοποίηση (Fuzzification).
3. Σύστημα ασαφούς συμπερασμού (Fuzzy Inference Engine).
4. Αποασαφοποίηση (Defuzzification).



Σχήμα 3.8 Αρχιτεκτονική ασαφούς συστήματος

Η βάση γνώσης περιλαμβάνει το σύνολο κανόνων και τις προϋποθέσεις IF-THEN που κατασκευάστηκαν για το σύστημα και τις συναρτήσεις συμμετοχής που θα

χρησιμοποιηθούν στους κανόνες του συστήματος. Στην συνέχεια χρησιμοποιείται η ασαφοποίηση για τη μετατροπή της εισόδου από ευκρινούς αριθμούς σε ασαφή σύνολα. Οι αρχικές εισοδοί, πλέον με την μορφή ασαφών συνόλων, εισάγονται στο σύστημα ασαφούς συμπερασμού (Fuzzy Inference Engine), το οποίο θα καθορίσει τον βαθμό αντιστοίχισης της τρέχουσας ασαφούς εισόδου σε σχέση με κάθε κανόνα και θα αποφασίσει ποιοι κανόνες θα ενεργοποιηθούν σύμφωνα με το πεδίο εισαγωγής. Από αυτή την διαδικασία θα προκύψει ένα τελικό ασαφές αποτέλεσμα. Τέλος με την χρήση της αποασαφοποίησης (Defuzzification) τα ασαφή σύνολα που λαμβάνονται από το σύστημα ασαφούς συμπερασμού μετατρέπονται σε ευκρινές τιμές. Υπάρχουν πολλές διαθέσιμες μέθοδοι αποασαφοποίησης και η καταλληλότερη χρησιμοποιείται για τη μείωση του σφάλματος.

3.1.8 Τύποι ασαφών συστημάτων (Fuzzy Inference Systems)

Τα Fuzzy Inference Systems (FIS) είναι ένας τύπος μαθηματικού μοντέλου που λειτουργεί με βάση τις αρχές της ασαφούς λογικής, η οποία είναι μια μέθοδος αντιμετώπισης της αβεβαιότητας και της ανακρίβειας στα δεδομένα.

Τα FIS χρησιμοποιούνται ευρέως σε διάφορους τομείς, συμπεριλαμβανομένης της μηχανικής, της επιστήμης των υπολογιστών και της τεχνητής νοημοσύνης, για τη μοντελοποίηση πολύπλοκων συστημάτων που περιλαμβάνουν ελλειπίες ή αβέβαιες πληροφορίες. Χρησιμοποιούν ένα σύνολο κανόνων και γλωσσικών μεταβλητών για να μετατρέψουν τα δεδομένα εισόδου σε δεδομένα εξόδου, καθιστώντας τα ιδιαίτερα χρήσιμα σε εφαρμογές όπου μπορεί να είναι δύσκολο να αναπτυχθούν ακριβή μαθηματικά μοντέλα.

Τα FIS έχουν εφαρμοστεί σε ένα ευρύ φάσμα προβλημάτων, συμπεριλαμβανομένων των συστημάτων ελέγχου, της λήψης αποφάσεων, της αναγνώρισης προτύπων και της πρόβλεψης, μεταξύ άλλων. Συνολικά παρέχουν ένα ευέλικτο και ισχυρό εργαλείο για τη μοντελοποίηση πολύπλοκων συστημάτων παρουσία αβεβαιότητας και ανακρίβειας.

Υπάρχουν πολλοί τύποι ασαφών συστημάτων που διαχωρίζονται με βάση τον μηχανισμό που χρησιμοποιείται για να εξαχθούν τα αποτελέσματα όμως στην παρούσα έρευνα θα αναφερθούν τα πιο σημαντικά.

Mamdani

Το Mamdani Fuzzy Inference System (FIS) προτάθηκε από τον Ebrahim Mamdani, και είναι ένας τύπος ελεγκτή ασαφούς λογικής που είναι ιδιαίτερα χρήσιμος όταν αντιμετωπίζουμε πολύπλοκα συστήματα όπου οι παραδοσιακές μέθοδοι ελέγχου αποτυγχάνουν να παρέχουν ικανοποιητικά αποτελέσματα. Χρησιμοποιήθηκε πρώτη φορά σαν μία προσπάθεια ελέγχου ενός συστήματος ατμομηχανής-λέβητα με την χρήση ενός συνόλου ασαφών κανόνων. Αρχικά εκτελείται ασαφοποίηση των τιμών εισόδου, στη συνέχεια γίνεται εκτίμηση των κανόνων που ακολουθείται από συνάντηση των συμπερασμάτων και τελικά την αποασαφοποίηση τους.

Ένας τυπικός ασαφής κανόνας για το ασαφές μοντέλο τύπου Mamdani έχει την ακόλουθη μορφή:

$$\text{Αν } X=A \text{ τότε } Y=B$$

$$(X=A) \Rightarrow (Y=B)$$

$$A=B$$

Στον παραπάνω κανόνα η πρόταση «το X είναι A» αποτελεί το αίτιο, ενώ η πρόταση «το Y είναι B» αποτελεί το αποτέλεσμα. Ένα σύστημα Mamdani περιλαμβάνει ένα σύνολο κανόνων προτάσεων της μορφής:

$$\text{«ΑΝ (X είναι A) ΤΟΤΕ (Y=B)»}$$

Sugeno

Το ασαφές μοντέλο τύπου Sugeno προτάθηκε από τους Tagaki, Sugeno και Kang σε μια προσπάθεια να αναπτύξουν μια συστηματική προσέγγιση που θα τους επιτρέψει την παραγωγή ασαφών κανόνων από ένα συγκεκριμένο σύνολο δεδομένων εισόδου-εξόδου. Το μοντέλο αυτό έχει αρκετές ομοιότητες με το Mamdani καθώς τα βήματα της ασαφοποίησης και της εφαρμογής των τελεστών είναι ίδια. Η διαφορά μεταξύ τους είναι ότι οι συναρτήσεις συμμετοχής στην έξοδο του μοντέλου Sugeno είναι γραμμικές ή σταθερές συναρτήσεις.

Ένας τυπικός ασαφής κανόνας για το ασαφές μοντέλο τύπου Sugeno έχει την ακόλουθη μορφή:

$$\text{Αν } x \text{ είναι } A \text{ και } y \text{ είναι } B, \text{ τότε } z = f(x,y),$$

όπου τα A και B είναι ασαφή σύνολα στην υπόθεση (antecedent), ενώ το $z = f(x,y)$ είναι μια σαφής (crisp) συνάρτηση στην απόδοση (consequent).

Συνήθως το $f(x,y)$ είναι ένα πολυώνυμο των μεταβλητών εισόδου x και y, αλλά μπορεί να είναι οποιαδήποτε συνάρτηση, αρκεί να μπορεί να περιγράψει κατάλληλα την έξοδο του μοντέλου εντός της ασαφούς περιοχής που καθορίζεται από την υπόθεση του κανόνα.

Tsukamoto

Στα ασαφή μοντέλα Tsukamoto, το αποτέλεσμα κάθε ασαφούς κανόνα if-then αντιπροσωπεύεται από ένα ασαφές σύνολο με μια μονότονη συνάρτηση συμμετοχής. Αυτό έχει ως αποτέλεσμα, η συναγόμενη έξοδος κάθε κανόνα να ορίζεται ως μια ευκρινή τιμή που καθορίζεται από τον βαθμό εκπλήρωσης του κάθε κανόνα. Η τελική έξοδος λαμβάνεται ως ο σταθμισμένος μέσος όρος των αποτελεσμάτων του κάθε κανόνα. Αξίζει να σημειωθεί ότι ενώ το μοντέλο Tsukamoto πλεονεκτεί ως προς την ταχύτητα υπολογισμού, καθώς δεν χρειάζεται να εφαρμοστεί η διαδικασία της

αποασαφοποίησης, υστερεί όμως ως προς την ακρίβεια και την αξιοπιστία των αποτελεσμάτων από τα μοντέλα Mamdani και Sugeno.

3.1.9 Μέθοδοι αποασαφοποίησης αποτελεσμάτων

Η αποασαφοποίηση είναι η διαδικασία λήψης ενός μόνο αριθμού από την έξοδο του συγκεντρωτικού ασαφούς συνόλου. Χρησιμοποιείται για τη μεταφορά των ασαφών αποτελεσμάτων σε μια ευκρινή έξοδο. Με άλλα λόγια, η αποασαφοποίηση πραγματοποιείται από έναν αλγόριθμο λήψης αποφάσεων που επιλέγει την καλύτερη ευκρινή τιμή με βάση ένα ασαφές σύνολο. Υπάρχουν διάφορες μέθοδοι αποασαφοποίησης και παρακάτω θα αναφερθούν μερικές από αυτές.

Μέθοδος Center of Sums (COS)

Αυτή είναι η πιο συχνά χρησιμοποιούμενη τεχνική αποασαφοποίησης. Σε αυτή τη μέθοδο, η επικαλυπτόμενη περιοχή μετρίεται δύο φορές.

Η αποασαφοποιημένη τιμή x^* ορίζεται ως:

$$x^* = \frac{\sum_{i=1}^N x_i \cdot \sum_{k=1}^n \mu_{A_k}(x_i)}{\sum_{i=1}^N \sum_{k=1}^n \mu_{A_k}(x_i)} \quad (26)$$

Όπου n είναι ο αριθμός των ασαφών συνόλων, N είναι ο αριθμός των ασαφών μεταβλητών και $\mu_{A_k}(x_i)$ είναι η συνάρτηση συμμετοχής του k -στού ασαφούς συνόλου.

Μέθοδος Center of gravity (COG) / Centroid of Area (COA)

Αυτή η μέθοδος παρέχει μια ευκρινή τιμή με βάση το κέντρο βάρους του ασαφούς συνόλου. Η συνολική έκταση της κατανομής της συνάρτησης συμμετοχής διαιρείται σε έναν αριθμό υποπεριοχών. Υπολογίζεται η περιοχή και το κέντρο βάρους ή το κεντροειδές κάθε υποπεριοχής και στη συνέχεια λαμβάνεται το άθροισμα όλων αυτών για να βρεθεί η αποασαφοποιημένη τιμή για ένα διακριτό ασαφές σύνολο.

Για διακριτές συναρτήσεις συμμετοχής, η αποασαφοποιημένη τιμή x^* ορίζεται ως:

$$x^* = \frac{\sum_{i=1}^n x_i \cdot \mu(x_i)}{\sum_{i=1}^n \mu(x_i)} \quad (27)$$

Όπου x_i είναι το στοιχείο του δείγματος, $\mu(x_i)$ είναι η συνάρτηση συμμετοχής και n είναι ο αριθμός των στοιχείων στο δείγμα.

Για συνεχείς συναρτήσεις συμμετοχής η αποασαφοποιημένη τιμή x^* ορίζεται ως:

$$x^* = \frac{\int x \mu_A(x) dx}{\int \mu_A(x) dx} \quad (28)$$

Μέθοδος Center of Area / Bisector of Area (BOA)

Αυτή η μέθοδος υπολογίζει τη θέση κάτω από την καμπύλη όπου οι περιοχές και στις δύο πλευρές είναι ίσες. Η μέθοδος BOA χωρίζει την περιοχή σε δύο μέρη με το ίδιο εμβαδόν.

$$\int_{\alpha}^{x^*} \mu_A(x) dx = \int_{x^*}^{\beta} \mu_A(x) dx \quad (29)$$

Όπου $\alpha = \min\{x | x \in X\}$ και $\beta = \max\{x | x \in X\}$

Μέθοδος Weighted Average

Αυτή η μέθοδος ισχύει για ασαφή σύνολα με συμμετρικές συναρτήσεις συμμετοχής στην έξοδο και παράγει αποτελέσματα πολύ κοντά στη μέθοδο COA. Αυτή η μέθοδος είναι λιγότερο απαιτητική υπολογιστικά. Κάθε συνάρτηση συμμετοχής σταθμίζεται σύμφωνα με τη μέγιστη τιμή συμμετοχής της.

Η αποασαφοποιημένη τιμή x^* ορίζεται ως

$$x^* = \frac{\sum \mu(x) \cdot x}{\sum \mu(x)} \quad (27)$$

Όπου \sum είναι το αλγεβρικό άθροισμα και x το στοιχείο με την μεγαλύτερη τιμή στην συνάρτηση συμμετοχής.

Μέθοδος First of Maxima (FOM)

Αυτή η μέθοδος καθορίζει τη μικρότερη τιμή της περιοχής με την μέγιστη τιμή συμμετοχής.

Μέθοδος Last of Maxima (LOM)

Αυτή η μέθοδος καθορίζει τη μεγαλύτερη τιμή της περιοχής με την μέγιστη τιμή συμμετοχής.

Μέθοδος Mean of Maxima (MOM)

Σε αυτή τη μέθοδο, η αποασαφοποιημένη τιμή λαμβάνεται ως το στοιχείο με τις υψηλότερες τιμές συμμετοχής. Όταν υπάρχουν περισσότερα από ένα στοιχεία με μέγιστες τιμές συμμετοχής, το μέγιστο λαμβάνεται από την μέση τιμή.

$$x^* = \frac{\sum_{x_i \in M} x_i}{|M|} \quad (28)$$

Όπου $M = \{x_i \mid \mu_A(x_i) = \text{με το ύψος του ασαφούς συνόλου } A\}$ και $|M|$ είναι το μέγεθος του συνόλου M .

3.2 Νευρωνικά Δίκτυα

3.2.1 Ιστορικά στοιχεία

Η ιστορία των νευρωνικών δικτύων είναι μεγαλύτερη από ό,τι πιστεύουν οι περισσότεροι. Ενώ η ιδέα μιας «μηχανής που σκέφτεται» μπορεί να ανιχνευθεί στους Αρχαίους Έλληνες, στην συγκεκριμένη έρευνα θα γίνει αναφορά στα βασικά γεγονότα που οδήγησαν στην εξέλιξη της σκέψης γύρω από τα νευρωνικά δίκτυα.

Το 1943 ο Warren S. McCulloch και ο Walter Pitts δημοσίευσαν την έρευνα «A logical calculus of the ideas immanent in nervous activity», η οποία προσπάθησε να κατανοήσει το πώς ο ανθρώπινος εγκέφαλος θα μπορούσε να παράγει πολύπλοκα μοτίβα μέσω συνδεδεμένων εγκεφαλικών κυττάρων ή νευρώνων. Μία από τις κύριες ιδέες που προέκυψαν από αυτήν την έρευνα ήταν η σύγκριση των νευρώνων με δυαδικό κατώφλι με την Boolean λογική (δηλαδή, 0/1 ή αληθείς/ψευδείς προτάσεις).

Το 1958 ο Frank Rosenblatt πιστώνεται με την ανάπτυξη του perceptron, όπως τεκμηριώνεται στην έρευνά του, «The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain». Πηγαίνει το έργο του McCulloch και του Pitt ένα βήμα παραπέρα εισάγοντας βάρη στην εξίσωση. Αξιοποιώντας έναν IBM 704, ο Rosenblatt κατάφερε να βάλει έναν υπολογιστή να μάθει πώς να ξεχωρίζει τις κάρτες που ήταν μαρκαρισμένες αριστερά από τις κάρτες που ήταν μαρκαρισμένες δεξιά.

Το 1974 ενώ πολλοί ερευνητές συνέβαλαν στην ιδέα της backpropagation, ο Paul Werbos ήταν ο πρώτος άνθρωπος στις ΗΠΑ που σημείωσε την εφαρμογή της στα νευρωνικά δίκτυα στο πλαίσιο της διδακτορικής του διατριβής.

Το 1989 ο Yann LeCun δημοσίευσε ένα άρθρο που επεξηγεί πώς η χρήση περιορισμών στην backpropagation και η ενσωμάτωσή της στην αρχιτεκτονική νευρωνικών δικτύων μπορεί να χρησιμοποιηθεί για την εκπαίδευση αλγορίθμων. Αυτή η έρευνα αξιοποίησε με επιτυχία ένα νευρωνικό δίκτυο για να αναγνωρίσει χειρόγραφα ψηφία ταχυδρομικού κώδικα που παρέχονται από την Ταχυδρομική Υπηρεσία των ΗΠΑ.

3.2.2 Δομή

Τα τεχνητά νευρωνικά δίκτυα (ANN), που συνήθως ονομάζονται απλά ως νευρωνικά δίκτυα (NN), είναι υπολογιστικά συστήματα εμπνευσμένα από τα βιολογικά νευρωνικά δίκτυα που αποτελούν τους εγκεφάλους των ζώων.

Ένα ANN βασίζεται σε μια συλλογή συνδεδεμένων μονάδων ή κόμβων που ονομάζονται τεχνητοί νευρώνες, οι οποίοι μοντελοποιούν τους νευρώνες σε έναν βιολογικό εγκέφαλο. Κάθε σύνδεση, όπως και οι συνάψεις σε έναν βιολογικό εγκέφαλο, μπορεί να μεταδώσει ένα σήμα σε άλλους νευρώνες. Ένας τεχνητός νευρώνας λαμβάνει σήματα και στη συνέχεια τα επεξεργάζεται και μπορεί να σηματοδοτήσει τους νευρώνες που συνδέονται με αυτόν. Το "σήμα" σε μια σύνδεση είναι ένας πραγματικός αριθμός και η έξοδος κάθε νευρώνα υπολογίζεται από κάποια μη γραμμική συνάρτηση του αθροίσματος των εισόδων του. Οι συνδέσεις ονομάζονται ακμές. Οι νευρώνες και τα άκρα έχουν συνήθως ένα βάρος που προσαρμόζεται καθώς προχωρά η μάθηση. Το βάρος αυξάνει ή μειώνει την ισχύ του σήματος σε μια σύνδεση. Οι νευρώνες μπορεί να έχουν ένα κατώφλι τέτοιο ώστε ένα σήμα να αποστέλλεται μόνο εάν το αθροιστικό σήμα υπερβαίνει αυτό το κατώφλι.

Υπάρχουν δύο είδη νευρώνων, οι νευρώνες εισόδου και οι υπολογιστικοί νευρώνες. Οι νευρώνες εισόδου (inputs) δεν υπολογίζουν τίποτα, μεσολαβούν ανάμεσα στις εισόδους του δικτύου και τους υπολογιστικούς νευρώνες.

Με μαθηματικούς όρους, μπορούμε να περιγράψουμε έναν νευρώνα k από το παρακάτω ζεύγος εξισώσεων :

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (29)$$

$$y_k = \Phi(u_k - b_k) \quad (30)$$

όπου x_1, x_2, \dots, x_m είναι τα εισερχόμενα σήματα, $w_{k1}, w_{k2}, \dots, w_{km}$ είναι τα βάρη των συνάψεων του νευρώνα k , u_k είναι η έξοδος του γραμμικού συνδιαστή, $\Phi(\cdot)$ είναι η συνάρτηση ενεργοποίησης και y_k είναι το σήμα που δίνει σαν έξοδο ο νευρώνας k .

Η δεύτερη εξίσωση δείχνει την ιδιαίτερη σημασία του βάρους b_k (κατώφλι). Εάν το συνολικό άθροισμα από τις υπόλοιπες εισόδους του νευρώνα είναι μεγαλύτερο από την τιμή αυτή, τότε ο νευρώνας ενεργοποιείται. Εάν είναι μικρότερο, τότε ο νευρώνας παραμένει ανενεργός.

Τυπικά, οι νευρώνες συγκεντρώνονται σε επίπεδα (layers). Διαφορετικά επίπεδα μπορεί να εκτελούν διαφορετικούς μετασχηματισμούς στις εισόδους τους. Τα σήματα ταξιδεύουν από το πρώτο επίπεδο (επίπεδο εισόδου), στο τελευταίο (επίπεδο εξόδου), πιθανώς αφού διασχίσουν τα επίπεδα πολλές φορές.

3.2.3 Συναρτήσεις ενεργοποίησης

Η συνάρτηση ενεργοποίησης σε ένα νευρωνικό δίκτυο ορίζει πώς το σταθμισμένο άθροισμα της εισόδου μετατρέπεται σε έξοδο από έναν κόμβο ή κόμβους σε ένα επίπεδο του δικτύου. Μερικές φορές η συνάρτηση ενεργοποίησης ονομάζεται και συνάρτηση μεταφοράς.

Η επιλογή της συνάρτησης ενεργοποίησης έχει μεγάλο αντίκτυπο στην ικανότητα και την απόδοση του νευρωνικού δικτύου και μπορεί να χρησιμοποιηθούν διαφορετικές συναρτήσεις ενεργοποίησης σε διαφορετικά μέρη του μοντέλου.

Υπάρχουν πολλοί διαφορετικοί τύποι συναρτήσεων ενεργοποίησης που χρησιμοποιούνται στα νευρωνικά δίκτυα, αν και ίσως μόνο ένας μικρός αριθμός συναρτήσεων χρησιμοποιούνται στην πράξη για κρυφά επίπεδα και επίπεδα εξόδου. Μερικές από αυτές τις συναρτήσεις θα αναφερθούν παρακάτω.

Συνάρτηση δυαδικού βήματος (Binary Step Function)


Η συνάρτηση δυαδικού βήματος εξαρτάται από μια τιμή κατωφλίου που αποφασίζει εάν ένας νευρώνας πρέπει να ενεργοποιηθεί ή όχι.

Η είσοδος που τροφοδοτείται στη συνάρτηση ενεργοποίησης συγκρίνεται με ένα συγκεκριμένο όριο. Εάν η είσοδος είναι μεγαλύτερη από αυτήν, τότε ο νευρώνας ενεργοποιείται, διαφορετικά απενεργοποιείται, που σημαίνει ότι η έξοδος του δεν μεταβιβάζεται στο επόμενο κρυφό στρώμα.

Ο μαθηματικός τύπος της συνάρτησης ορίζεται ως:

$$f(x) = \begin{cases} 0 & \text{for } x < 0 \\ 1 & \text{for } x \geq 0 \end{cases} \quad (31)$$

Στο σχήμα 3.9 παρουσιάζεται και η γραφική απεικόνιση της συνάρτησης αυτής.



Σχήμα 3.9 Γραφική απεικόνιση της συνάρτησης δυαδικού βήματος


Γραμμική συνάρτηση (Linear Activation Function)

Η συνάρτηση γραμμικής ενεργοποίησης, γνωστή και ως "χωρίς ενεργοποίηση" ή "συνάρτηση ταυτότητας", είναι αυτή όπου η ενεργοποίηση είναι ανάλογη με την είσοδο. Η συνάρτηση δεν κάνει τίποτα στο σταθμισμένο άθροισμα της εισόδου, απλώς έχει ως έξοδο την τιμή που της δόθηκε.

Ο μαθηματικός τύπος της συνάρτησης ορίζεται ως:

$$f(x) = x \quad (32)$$

Στο σχήμα 3.10 παρουσιάζεται και η γραφική απεικόνιση της συνάρτησης αυτής.



Σχήμα 3.10 Γραφική απεικόνιση της γραμμικής συνάρτησης


Σιγμοειδής / Λογιστική συνάρτηση (Sigmoid / Logistic Activation Function)

Αυτή η συνάρτηση παίρνει οποιαδήποτε πραγματική τιμή ως είσοδο και εξάγει τιμές στην περιοχή από 0 έως 1. Όσο μεγαλύτερη είναι η είσοδος (πιο θετική), τόσο πιο κοντά η τιμή εξόδου θα είναι στο 1.0, ενώ όσο μικρότερη είναι η είσοδος (πιο αρνητική), τόσο πιο κοντά η εξόδος θα είναι στο 0.0.

Ο μαθηματικός τύπος της συνάρτησης ορίζεται ως:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (33)$$

Στο σχήμα 3.11 παρουσιάζεται και η γραφική απεικόνιση της συνάρτησης αυτής.



Σχήμα 3.11 Γραφική απεικόνιση της σιγμοειδούς συνάρτησης


Συνάρτηση υπερβολικής εφαπτομένης (Tanh Function)

Η συνάρτηση Tanh είναι πολύ παρόμοια με τη σιγμοειδή συνάρτηση ενεργοποίησης και έχει ακόμη και το ίδιο σχήμα “S” με διαφορά στην περιοχή εξόδου από -1 έως 1. Στην συνάρτηση υπερβολικής εφαπτομένης, όσο μεγαλύτερη είναι η είσοδος (πιο θετική), τόσο πιο κοντά η τιμή εξόδου θα είναι στο 1.0, ενώ όσο μικρότερη είναι η είσοδος (πιο αρνητική), τόσο πιο κοντά η τιμή εξόδου θα είναι στο -1.0.

Ο μαθηματικός τύπος της συνάρτησης ορίζεται ως:

$$f(x) = \frac{(e^x - e^{-x})}{(e^x + e^{-x})} \quad (34)$$

Στο σχήμα 3.12 παρουσιάζεται και η γραφική απεικόνιση της συνάρτησης αυτής.



Σχήμα 3.12 Γραφική απεικόνιση της συνάρτησης υπερβολικής εφαπτομένης

Συνάρτηση ReLU (Rectified Linear Unit)


Αν και δίνει την εντύπωση μιας γραμμικής συνάρτησης, η ReLU έχει μια παράγωγη συνάρτηση και επιτρέπει την αντίστροφη διάδοση (backpropagation) ενώ ταυτόχρονα είναι και υπολογιστικά αποδοτική.

Το κύριο πρόβλημα εδώ είναι ότι η λειτουργία ReLU δεν ενεργοποιεί όλους τους νευρώνες ταυτόχρονα. Οι νευρώνες θα απενεργοποιηθούν μόνο εάν η έξοδος του γραμμικού μετασχηματισμού είναι μικρότερη από 0.

Ο μαθηματικός τύπος της συνάρτησης ορίζεται ως:

$$f(x) = \max(0, x) \quad (34)$$

Στο σχήμα 3.13 παρουσιάζεται και η γραφική απεικόνιση της συνάρτησης αυτής.

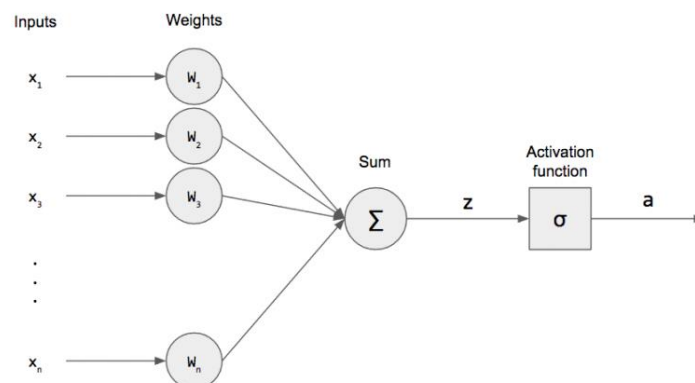


Σχήμα 3.13 Γραφική απεικόνιση της συνάρτησης ReLu

3.2.4 Αρχιτεκτονικές

Perceptron

Το Perceptron είναι η απλούστερη αρχιτεκτονική νευρωνικών δικτύων. Είναι ένας τύπος νευρωνικού δικτύου που λαμβάνει έναν αριθμό εισόδων, εφαρμόζει ορισμένες μαθηματικές πράξεις σε αυτές και παράγει μια έξοδο. Παίρνει ένα διάνυσμα πραγματικών τιμών εισόδου και εκτελεί έναν γραμμικό συνδυασμό κάθε χαρακτηριστικού με το αντίστοιχο βάρος που έχει εκχωρηθεί σε καθένα από αυτά. Η σταθμισμένη είσοδος αθροίζεται σε μία μόνο τιμή και περνά μέσα από μια συνάρτηση ενεργοποίησης. Αυτές οι μονάδες perceptron συνδυάζονται για να σχηματίσουν μια μεγαλύτερη αρχιτεκτονική τεχνητού νευρωνικού δικτύου. Στο σχήμα 3.14 παρουσιάζεται η μορφή ενός perceptron.




Σχήμα 3.14 Μορφή ενός perceptron.

Feed-Forward Networks

Όπως αναφέρθηκε παραπάνω το Perceptron αντιπροσωπεύει την λειτουργία ενός μεμονωμένου νευρώνα. Με μια σειρά από perceptron στοιβαγμένα σε μια σειρά και στοιβαγμένα σε διαφορετικά στρώματα σχηματίζουν μια μεγαλύτερη αρχιτεκτονική τεχνητού νευρωνικού δικτύου.

Το Feed-Forward Network είναι ένα πολυεπίπεδο νευρωνικό δίκτυο και, όπως υποδηλώνει το όνομα, οι πληροφορίες μεταβιβάζονται προς την εμπρός κατεύθυνση, από αριστερά προς τα δεξιά. Στο μπροστινό πέρασμα, οι πληροφορίες έρχονται μέσα στο μοντέλο μέσω του επιπέδου εισόδου, περνούν από τη σειρά των κρυφών επιπέδων και τελικά πηγαίνουν στο επίπεδο εξόδου. Αυτή η αρχιτεκτονική των νευρωνικών δικτύων είναι από τη φύση της προς τα εμπρός, οι πληροφορίες δεν επαναλαμβάνονται με δύο κρυφά επίπεδα. Τα τελευταία επίπεδα δεν δίνουν ανάδραση στα προηγούμενα επίπεδα. Η βασική διαδικασία εκμάθησης των Feed-Forward Networks παραμένει η ίδια με το perceptron. Στο σχήμα 3.15 παρουσιάζεται η μορφή ενός Feed-Forward Network.




Σχήμα 3.15 Μορφή ενός Feed-Forward Network.

Recurrent Neural Networks (RNN)

Η βασική αρχιτεκτονική βαθιάς εκμάθησης έχει ένα σταθερό μέγεθος εισόδου και αυτό λειτουργεί ως εμπόδιο σε σενάρια όπου το μέγεθος εισόδου δεν είναι σταθερό. Επίσης, οι αποφάσεις που ελήφθησαν από το μοντέλο βασίζονται στην τρέχουσα είσοδο χωρίς ανάμνηση του παρελθόντος.

Τα Recurrent Neural Networks λειτουργούν πολύ καλά με αλληλουχίες δεδομένων ως είσοδο. Η λειτουργικότητά του μπορεί να φανεί στην επίλυση προβλημάτων NLP όπως ανάλυση συναισθήματος, φίλτρα ανεπιθύμητης αλληλογραφίας, προβλήματα χρονοσειρών όπως πρόβλεψη πωλήσεων, πρόβλεψη χρηματιστηρίου κ.λπ.

Τα Recurrent Neural Networks έχουν τη δύναμη να θυμούνται όσα έχουν μάθει στο παρελθόν και να τα εφαρμόζουν σε μελλοντικές προβλέψεις. Η είσοδος έχει τη μορφή διαδοχικών δεδομένων που τροφοδοτούνται στο RNN, το οποίο έχει μια κρυφή εσωτερική κατάσταση που ενημερώνεται κάθε φορά που διαβάζει την ακόλουθη ακολουθία δεδομένων στην είσοδο. Η εσωτερική κρυφή κατάσταση θα ανατροφοδοτηθεί στο μοντέλο. Στο σχήμα 3.16 παρουσιάζεται η μορφή ενός Recurrent Neural Network.



Σχήμα 3.16 Μορφή ενός Recurrent Neural Network.

Convolutional Neural Networks (CNN)


Τα Convolutional Neural Networks είναι ένας τύπος Feed-Forward νευρωνικών δικτύων που χρησιμοποιούνται σε εργασίες όπως ανάλυση εικόνας, επεξεργασία φυσικής γλώσσας και άλλα σύνθετα προβλήματα ταξινόμησης εικόνων.

Ένα CNN έχει κρυφά επίπεδα συνελκτικών επιπέδων που αποτελούν τη βάση των ConvNets. Τα συνελκτικά επίπεδα ανιχνεύουν τα μοτίβα των χαρακτηριστικών στα δεδομένα της εικόνας με τη βοήθεια φίλτρων. Οι υψηλότερου επιπέδου λεπτομέρειες φροντίζονται από τα πρώτα συνελκτικά επίπεδα. Ως χαρακτηριστικά αναφέρονται οι μικρές λεπτομέρειες στα δεδομένα της εικόνας, όπως ακμές, περιγράμματα, σχήματα, υφές, αντικείμενα, κύκλοι κ.λπ.

Όσο πιο μεγάλο το βάθος του δικτύου, τόσο πιο περίπλοκη γίνεται η αναζήτηση μοτίβων. Για παράδειγμα, σε μεταγενέστερα επίπεδα εκτός από ακμές και απλά σχήματα, τα φίλτρα μπορεί να ανιχνεύσουν συγκεκριμένα αντικείμενα όπως μάτια ή αυτιά και τελικά μια γάτα, έναν σκύλο και άλλα.

Η έξοδος του συνελκτικού επιπέδου περνά συνήθως μέσω της συνάρτησης ενεργοποίησης ReLU για να φέρει μη γραμμικότητα στο μοντέλο. Παίρνει τον χάρτη χαρακτηριστικών και αντικαθιστά όλες τις αρνητικές τιμές με μηδέν.

Στο σχήμα 3.17 παρουσιάζεται η μορφή ενός Convolutional Neural Network.



Σχήμα 3.17 Μορφή ενός Convolutional Neural Network.

3.2.5 Εκπαίδευση - Μάθηση

Η εκπαίδευση ενός δικτύου βασίζεται στην ανάστροφη μετάδοση του σφάλματος (back propagation). Η αναπροσαρμογή των βαρών γίνεται από το επίπεδο εξόδου προς το επίπεδο εισόδου με εφαρμογή της διαδικασίας βελτιστοποίησης επικλινούς καθόδου (gradient descent optimization procedure) που ελαχιστοποιεί το μέσο τετραγωνικό σφάλμα μεταξύ της εξόδου του δικτύου και της επιθυμητής εξόδου, για ένα συγκεκριμένο πλήθος διανυσμάτων εκπαίδευσης. Η εκπαίδευση τελειώνει όταν τα αποτελέσματα που δίνει βρίσκονται εντός κάποιων προδιαγραφών που δίνονται από τον χρήστη ή/και την μορφή του προβλήματος.

Εξαιρετικά σημαντικός παράγοντας στην εκπαίδευση ενός νευρωνικού δικτύου είναι ο αριθμός εποχών εκπαίδευσης. Ως εποχή (epoch) εννοείται η χρήση όλων των δεδομένων εκπαίδευσης (από το δίκτυο) για μία φορά. Μικρός αριθμός εποχών εκπαίδευσης συνήθως οδηγεί σε άσχημα αποτελέσματα ενώ αντίθετα μεγάλος αριθμός εποχών εκπαίδευσης οδηγεί στην υπερεκπαίδευση και απαιτεί μεγάλο υπολογιστικό χρόνο. Υπερεκπαίδευση έχουμε όταν το νευρωνικό δίκτυο προσαρμοστεί πολύ καλά στα δεδομένα εκπαίδευσης και μόνο σε αυτά. Αξίζει να σημειωθεί ότι η έννοια μικρός και μεγάλος αριθμός εποχών εξαρτάται από το εκάστοτε πρόβλημα.

Υπάρχουν τρεις μορφές εκπαίδευσης νευρωνικών δικτύων, οι οποίες θα αναφερθούν παρακάτω.

Εκπαίδευση με επίβλεψη (supervised learning)

Η εποπτευόμενη μάθηση είναι μια προσέγγιση μηχανικής μάθησης που ορίζεται από τη χρήση συνόλων δεδομένων με ετικέτες. Αυτά τα σύνολα δεδομένων έχουν σχεδιαστεί για να εκπαιδεύουν ή να «εποπτεύουν» αλγόριθμους για την ταξινόμηση δεδομένων ή την ακριβή πρόβλεψη των αποτελεσμάτων. Χρησιμοποιώντας εισόδους και εξόδους με ετικέτα, το μοντέλο μπορεί να μετρήσει την ακρίβειά του και να μάθει με την πάροδο του χρόνου. Η εποπτευόμενη μάθηση μπορεί να χωριστεί σε δύο τύπους προβλημάτων κατά την διαδικασία της εξόρυξης δεδομένων, της ταξινόμησης και της παλινδρόμησης.

Εκπαίδευση χωρίς επίβλεψη (unsupervised learning)

Η μη εποπτευόμενη μάθηση χρησιμοποιεί αλγόριθμους μηχανικής μάθησης για την ανάλυση και τη ομαδοποίηση συνόλων δεδομένων χωρίς ετικέτα. Αυτοί οι αλγόριθμοι ανακαλύπτουν κρυφά μοτίβα σε δεδομένα χωρίς την ανάγκη ανθρώπινης παρέμβασης (επομένως, είναι «χωρίς επίβλεψη»). Τα μοντέλα μάθησης χωρίς επίβλεψη χρησιμοποιούνται για τρεις κύριες εργασίες, την ομαδοποίηση, την συσχέτιση και την μείωση διαστάσεων.

Ενισχυτική μάθηση (Reinforcement learning)

Η ενισχυτική μάθηση (RL) είναι ένας τομέας της μηχανικής μάθησης που ασχολείται με το πώς οι ευφυείς πράκτορες πρέπει να αναλαμβάνουν ενέργειες σε ένα περιβάλλον προκειμένου να μεγιστοποιήσουν την έννοια της αθροιστικής ανταμοιβής.


Η ενισχυτική μάθηση διαφέρει από την εποπτευόμενη μάθηση στο ότι δεν χρειάζεται να παρουσιαστούν ζεύγη εισόδου/εξόδου με ετικέτες και στο ότι δεν χρειάζεται να διορθωθούν ρητά οι μη βέλτιστες ενέργειες. Αντίθετα, η εστίαση είναι στην εξεύρεση της ισορροπίας μεταξύ της εξερεύνησης της “αχαρτογράφητης περιοχής” και της εκμετάλλευσης της τρέχουσας γνώσης.

3.3 ANFIS (Adaptive Neuro-Fuzzy Inference System)

3.3.1 Εισαγωγή

Το Adaptive Neuro-Fuzzy Inference System (ANFIS) είναι ένα υβριδικό υπολογιστικό μοντέλο που συνδυάζει τη δύναμη της ασαφούς λογικής και των νευρωνικών δικτύων για να δημιουργήσει ένα ισχυρό και αποτελεσματικό σύστημα για την επίλυση πολύπλοκων προβλημάτων. Το ANFIS αναπτύχθηκε από τον Jang το 1993 και έκτοτε έχει χρησιμοποιηθεί ευρέως σε διάφορους τομείς, συμπεριλαμβανομένων των συστημάτων ελέγχου, της επεξεργασίας σήματος και της ανάλυσης δεδομένων.

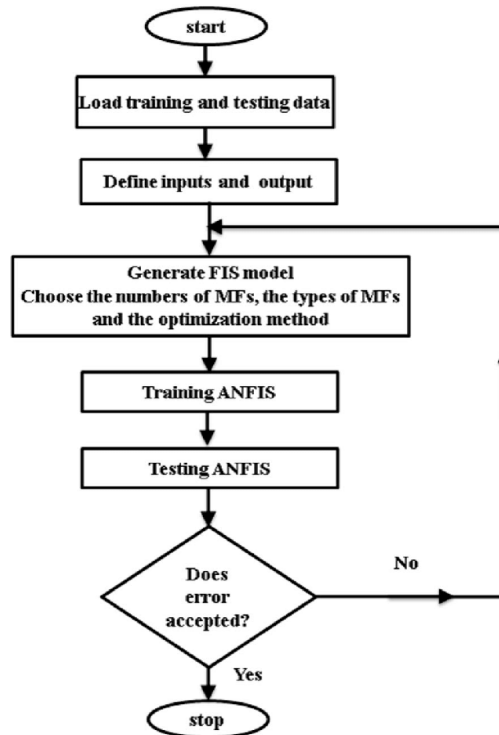
Η αρχιτεκτονική ANFIS αποτελείται από πέντε επίπεδα, συμπεριλαμβανομένου του επιπέδου εισόδου, του ασαφούς επιπέδου, του επιπέδου κανονικοποίησης, του επιπέδου κανόνα και του επιπέδου εξόδου. Το επίπεδο εισόδου λαμβάνει τις μεταβλητές εισόδου, οι οποίες στη συνέχεια περνούν μέσα από το ασαφές επίπεδο που εφαρμόζει τη θεωρία ασαφών συνόλων για να μετατρέψει τις εισόδους σε γλωσσικούς όρους. Στη συνέχεια, οι κανονικοποιημένες είσοδοι περνούν μέσα από το επίπεδο κανόνα, το οποίο καθορίζει την ισχύ του κανόνα και εξάγει την επακόλουθη τιμή. Τέλος, το επίπεδο εξόδου συνδυάζει τις επακόλουθες τιμές και παράγει την τελική έξοδο. Στο ANFIS, οι κόμβοι αναφέρονται στις μονάδες που επεξεργάζονται τις εισόδους και δημιουργούν τις εξόδους. Η αρχιτεκτονική ANFIS αποτελείται από κόμβους που μπορούν να είναι προσαρμοστικοί ή σταθεροί, ανάλογα με τον ρόλο τους στο σύστημα.



Σχήμα 3.18 Αρχιτεκτονική Μοντέλου ANFIS.

Ένας προσαρμοστικός κόμβος είναι ένας τύπος κόμβου που περιέχει ρυθμιζόμενες παραμέτρους που μπορούν να μαθευτούν και να ενημερωθούν κατά τη διάρκεια της εκπαιδευτικής διαδικασίας. Αυτές οι παράμετροι ενημερώνονται χρησιμοποιώντας έναν αλγόριθμο εκμάθησης που προσαρμόζει τα βάρη και τα κατώφλια του κόμβου για να βελτιώσει την ακρίβεια της εξόδου. Οι προσαρμοστικοί κόμβοι βρίσκονται συνήθως στο ασαφές επίπεδο του ANFIS, όπου χρησιμοποιούν τη θεωρία ασαφούς συνόλου για να μετατρέψουν τα δεδομένα εισόδου σε γλωσσικούς όρους. Οι παράμετροι αυτών των κόμβων ενημερώνονται με βάση το σφάλμα μεταξύ της πραγματικής εξόδου και της επιθυμητής εξόδου, επιτρέποντας στον κόμβο να προσαρμοστεί στις αλλαγές στα δεδομένα εισόδου και να βελτιώσει την ακρίβειά του.

Από την άλλη πλευρά, ένας σταθερός κόμβος είναι ένας τύπος κόμβου που περιέχει σταθερές παραμέτρους που δεν αλλάζουν κατά τη διάρκεια της εκπαιδευτικής διαδικασίας. Αυτοί οι κόμβοι βρίσκονται συνήθως στο επίπεδο κανόνων του ANFIS, όπου χρησιμοποιούν την έξοδο του ασαφούς επιπέδου για να δημιουργήσουν την έξοδο του συστήματος. Οι παράμετροι αυτών των κόμβων είναι σταθερές και καθορίζονται με βάση τους κανόνες του συστήματος και δεν αλλάζουν κατά τη διάρκεια της εκπαιδευτικής διαδικασίας.



Σχήμα 3.19 Διάγραμμα ροής μοντέλου ANFIS.

Ένα από τα κύρια πλεονεκτήματα του ANFIS είναι η ικανότητά του να μαθαίνει και να προσαρμόζεται σε μεταβαλλόμενα περιβάλλοντα. Το ANFIS χρησιμοποιεί έναν υβριδικό αλγόριθμο εκμάθησης που συνδυάζει τη μέθοδο gradient descent και τον αλγόριθμο backpropagation για να ενημερώσει τις παραμέτρους του μοντέλου. Αυτό επιτρέπει στο σύστημα να μαθαίνει από δεδομένα και να προσαρμόζει τις παραμέτρους του για να βελτιώσει την απόδοσή του. Το ANFIS έχει επίσης τη δυνατότητα να χειρίζεται μη γραμμικά και πολύπλοκα συστήματα με τα οποία οι παραδοσιακές μέθοδοι μπορεί να δυσκολεύονται, καθιστώντας το ένα πολύτιμο εργαλείο για διάφορες εφαρμογές.

3.3.2 Αρχιτεκτονική

Τα πέντε επίπεδα του μοντέλου ANFIS θα αναλυθούν περαιτέρω παρακάτω.

Επίπεδο 1

Κάθε κόμβος i σε αυτό το επίπεδο είναι ένας προσαρμοστικός (adaptive) κόμβος με συνάρτηση κόμβου :

$$O_{1,i} = \mu_{Ai}(x) \text{ για } i = 1, 2 \text{ ή} \quad (35)$$

$$O_{1,i} = \mu_{Bi-2}(x) \text{ για } i = 3, 4 \quad (36)$$

Όπου x (ή y) είναι ο κόμβος εισόδου του i και Ai (ή Bi-2) είναι η λεκτική μεταβλητή που σχετίζεται με αυτόν τον κόμβο.

Γενικά $O_{1,i}$ είναι η έξοδος του i-στου κόμβου στο επίπεδο 1.

Άρα $O_{1,i}$ είναι ο βαθμός συμμετοχής ενός ασαφούς συνόλου (A1,A2,B1,B2).

Εδώ η συνάρτηση συμμετοχής για το A μπορεί να είναι οποιαδήποτε κατάλληλη παραμετρική συνάρτηση συμμετοχής όπως η καμπανοειδής για παράδειγμα :

$$\mu_A(x) = \frac{1}{1 + \left| \frac{x-c_i}{a_i} \right|^{2b_i}} \quad (37)$$

Όπου $\{a_i, b_i, c_i\}$ είναι το σύνολο των παραμέτρων.

Οι παράμετροι σε αυτό το επίπεδο αναφέρονται ως αρχικές παράμετροι (premise parameters).

Επίπεδο 2

Κάθε κόμβος σε αυτό το επίπεδο είναι ένας σταθερός (fixed) κόμβος, του οποίου η έξοδος είναι το γινόμενο όλων των εισερχόμενων σημάτων. Όπως φαίνεται στο σχήμα 3.18 κάθε κόμβος αυτού του επιπέδου φέρει το όνομα Prod.

Η συνάρτηση κόμβου σε αυτό το επίπεδο ορίζεται ως:

$$O_{2,i} = w_i = \mu_{Ai}(x) * \mu_{Bi}(y), \quad i = 1, 2 \quad (38)$$

Κάθε κόμβος αντιπροσωπεύει τον βαθμό ενεργοποίησης ενός κανόνα (firing strength). Οποιοσδήποτε άλλος τελεστής T-norm που μπορεί να εκτελέσει την λογική πράξη ΚΑΙ μπορεί να χρησιμοποιηθεί ως συνάρτηση κόμβου σε αυτό το επίπεδο.

Επίπεδο 3

Σε αυτό το επίπεδο γίνεται η διαδικασία της κανονικοποίησης των βαθμών ενεργοποίησης. Κάθε κόμβος σε αυτό το επίπεδο είναι ένας σταθερός (fixed) κόμβος. Ο i-ιστός κόμβος υπολογίζει το λόγο του βαθμού ενεργοποίησης (firing strength) του i-οστού κανόνα στο άθροισμα των βαθμών ενεργοποίησης όλων των κανόνων. Όπως φαίνεται στο σχήμα 3.18 κάθε κόμβος αυτού του επιπέδου φέρει το όνομα Norm.

Η συνάρτηση κόμβου σε αυτό το επίπεδο ορίζεται ως:

$$O_{3,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i = 1, 2 \quad (39)$$

Οι έξοδοι αυτού του επιπέδου ονομάζονται κανονικοποιημένοι βαθμοί ενεργοποίησης (normalized firing strengths).

Επίπεδο 4

Σε αυτό το στάδιο λαμβάνει χώρα η αξιολόγηση του δεξιού μέρους των πολωνύμων. Κάθε κόμβος i σε αυτό το επίπεδο είναι ένας προσαρμόσιμος κόμβος με μία συνάρτηση κόμβου :

$$O_{4,1} = \bar{w}_i f_i = \bar{w}_i (p_x + q_i y + r_i) \quad (40)$$

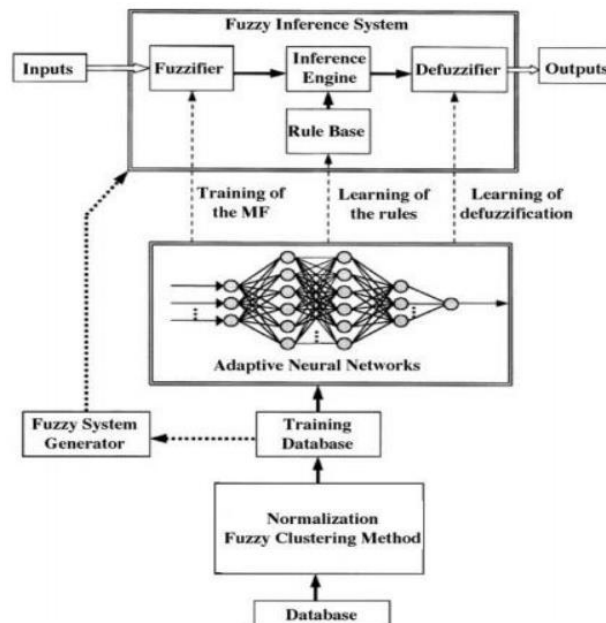
Όπου \bar{w}_i είναι ο κανονικοποιημένος βαθμός ενεργοποίησης από το επίπεδο 3 και $\{p_i, q_i, r_i\}$ το σύνολο των παραμέτρων αυτού του κόμβου. Οι παράμετροι σε αυτό το επίπεδο αναφέρονται ως επακόλουθοι (consequent parameters).

Επίπεδο 5

Ο μοναδικός κόμβος σε αυτό το επίπεδο είναι ένας σταθερός (fixed) κόμβος, που υπολογίζει τη συνολική έξοδο σαν το ολικό άθροισμα όλων των εισερχόμενων σημάτων. Όπως φαίνεται στο σχήμα 3.18 κάθε κόμβος αυτού του επιπέδου φέρει το όνομα Sum.

Η συνάρτηση κόμβου σε αυτό το επίπεδο ορίζεται ως:

$$overall\ output = O_{5,1} = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (41)$$



Σχήμα 3.20 Αρχιτεκτονική μοντέλου ANFIS, όπως αναπτύχθηκε από τον Jang.

3.4 Μοντέλα Ανάλυσης Χρονοσειρών (Time Series Models)

3.4.1 Εισαγωγή

Τα μοντέλα χρονοσειρών είναι στατιστικές τεχνικές που χρησιμοποιούνται για την ανάλυση και την πρόβλεψη δεδομένων που συλλέγονται για μια συγκεκριμένη χρονική περίοδο. Σε πολλούς τομείς, συμπεριλαμβανομένων των οικονομικών, των χρηματοοικονομικών, της πρόβλεψης του καιρού και της επεξεργασίας σημάτων, η κατανόηση και η πρόβλεψη μοτίβων σε χρονικά μεταβαλλόμενα δεδομένα έχει μεγάλη σημασία. Τα μοντέλα χρονοσειρών παρέχουν ένα πλαίσιο για την καταγραφή της υποκείμενης δυναμικής, των τάσεων και των μοτίβων σε τέτοια δεδομένα, επιτρέποντάς να ληφθούν τεκμηριωμένες αποφάσεις και προβλέψεις. Τα δεδομένα χρονοσειρών περιλαμβάνουν τη διαδοχική καταγραφή των παρατηρήσεων σε τακτά χρονικά διαστήματα, όπως ημερήσια, μηνιαία ή ετήσια. Παραδείγματα δεδομένων χρονοσειρών περιλαμβάνουν τιμές μετοχών, ρυθμούς αύξησης του ΑΕΠ, καταγραφές θερμοκρασίας και στοιχεία πωλήσεων. Το μοναδικό χαρακτηριστικό των δεδομένων χρονοσειρών είναι ότι οι παρατηρήσεις εξαρτώνται από τη σειρά τους και παρουσιάζουν χρονικούς συσχετισμούς. Τα μοντέλα χρονοσειρών στοχεύουν να αποκαλύψουν τη δομή μέσα στα δεδομένα και να κάνουν προβλέψεις με βάση τα ιστορικά μοτίβα που παρατηρούνται. Αυτά τα μοντέλα μπορούν να κατηγοριοποιηθούν ευρέως σε δύο τύπους: περιγραφικά μοντέλα και μοντέλα πρόβλεψης.

Τα περιγραφικά μοντέλα χρονοσειρών επικεντρώνονται στην κατανόηση των χαρακτηριστικών και των ιδιοτήτων των δεδομένων. Παρέχουν πληροφορίες για τα υποκείμενα μοτίβα, τις τάσεις, την εποχικότητα και άλλα χαρακτηριστικά που υπάρχουν στη χρονοσειρά. Περιγραφικά μοντέλα, όπως τα AutoRegressive (AR), Moving Average (MA) και AutoRegressive Integrated Moving Average (ARIMA), βοηθούν στον εντοπισμό των σχέσεων και των εξαρτήσεων μεταξύ των προηγούμενων παρατηρήσεων με σκοπό την περιγραφή της συμπεριφοράς των χρονοσειρών.

Τα μοντέλα πρόβλεψης, από την άλλη πλευρά, χρησιμοποιούν τις πληροφορίες που περιέχονται στα ιστορικά δεδομένα για να κάνουν προβλέψεις σχετικά με τις μελλοντικές τιμές. Αυτά τα μοντέλα είναι ζωτικής σημασίας για τη λήψη αποφάσεων, τον προγραμματισμό και τη διαμόρφωση πολιτικής. Αποτυπώνοντας τα μοτίβα και τις τάσεις που παρατηρήθηκαν στο παρελθόν, τα μοντέλα πρόβλεψης προβάλλουν τις αναμενόμενες τιμές και την αβεβαιότητα της χρονοσειράς στο μέλλον. Παραδείγματα μοντέλων πρόβλεψης περιλαμβάνουν μοντέλα εκθετικής εξομάλυνσης (exponential smoothing), Seasonal ARIMA μοντέλα και Vector AutoRegression (VAR) μοντέλα.

Συνολικά, τα μοντέλα χρονοσειρών διαδραματίζουν θεμελιώδη ρόλο στην κατανόηση, την ανάλυση και την πρόβλεψη δεδομένων που εξαρτώνται από το χρόνο. Αξιοποιώντας ιστορικές πληροφορίες και καταγράφοντας τα υποκείμενα μοτίβα, αυτά τα μοντέλα παρέχουν πολύτιμες γνώσεις και προβλέψεις που μπορούν να βοηθήσουν στη λήψη αποφάσεων και τον προγραμματισμό σε ένα ευρύ φάσμα τομέων.

3.4.2 Μοντέλο AR (AutoRegressive Model)

Τα AutoRegressive μοντέλα (AR) χρησιμοποιούνται στην ανάλυση χρονοσειρών για την περιγραφή σταθερών χρονοσειρών. Αυτά τα μοντέλα αντιπροσωπεύουν χρονοσειρές που δημιουργούνται περνώντας τον λευκό θόρυβο μέσω ενός αναδρομικού γραμμικού φίλτρου. Ωστόσο, η έξοδος ενός τέτοιου φίλτρου τη στιγμή t ζυγίζει το άθροισμα των m προηγούμενων τιμών της εξόδου του φίλτρου. Η ακέραια παράμετρος m ονομάζεται τάξη του μοντέλου AR. Το μοντέλο AR μιας τυχαίας διεργασίας $y(t)$ σε διακριτό χρόνο t ορίζεται από την ακόλουθη έκφραση:

$$y(t) = \sum_{i=1}^m a(i) \cdot y(t-i) + \varepsilon(t) \quad (42)$$

όπου a_1, a_2, \dots, a_m είναι οι συντελεστές του αναδρομικού φίλτρου, m είναι η τάξη του μοντέλου και $\varepsilon(t)$ είναι τα ασυσχέτιστα σφάλματα εξόδου.

3.4.3 Μοντέλο MA (Moving Average Model)

Τα Moving Average μοντέλα (MA) αντιπροσωπεύουν χρονοσειρές που δημιουργούνται περνώντας τον λευκό θόρυβο μέσω ενός μη αναδρομικού γραμμικού φίλτρου. Το μοντέλο MA μιας τυχαίας διεργασίας $y(t)$ σε διακριτό χρόνο t ορίζεται από την ακόλουθη έκφραση:

$$y(t) = \sum_{i=1}^n b(i) \cdot x(t-i) + \varepsilon(t) \quad (43)$$

όπου $b_i, i = 0, 1, \dots, n$ είναι οι συντελεστές του γραμμικού μη αναδρομικού φίλτρου, n είναι η τάξη του μοντέλου MA, $x(t)$ είναι το στοιχείο (εισόδου) του λευκού θορύβου και $\varepsilon(t)$ είναι τα ασυσχέτιστα σφάλματα εξόδου.

3.4.4 Μοντέλο ARMA (AutoRegressive Moving Average Model)

Τα AutoRegressive Moving Average μοντέλα (ARMA) χρησιμοποιούνται στην ανάλυση χρονοσειρών για την περιγραφή των σταθερών χρονοσειρών. Αυτά τα μοντέλα αντιπροσωπεύουν χρονοσειρές που δημιουργούνται με τη διέλευση λευκού θορύβου μέσω ενός αναδρομικού και μη αναδρομικού γραμμικού φίλτρου, διαδοχικά. Με άλλα λόγια, το μοντέλο ARMA είναι ένας συνδυασμός ενός μοντέλου AR μοντέλου MA.

Η τάξη του μοντέλου ARMA σε διακριτό χρόνο t περιγράφεται από δύο ακέραιους αριθμούς (m, n), οι οποίοι είναι οι τάξεις των τμημάτων AR και MA, αντίστοιχα. Η γενική έκφραση για μια διεργασία ARMA $y(t)$ είναι η εξής:

$$y(t) = \sum_{i=1}^m a(i) \cdot y(t-i) + \sum_{i=0}^n b(i) \cdot x(t-i) + \varepsilon(t) \quad (44)$$

όπου m είναι η τάξη του τμήματος AR του μοντέλου ARMA, a_1, a_2, \dots, a_m είναι οι συντελεστές του τμήματος AR του μοντέλου (του αναδρομικού γραμμικού φίλτρου), n είναι η τάξη του τμήματος MA του μοντέλου ARMA, ενώ b_0, b_1, \dots, b_n είναι οι συντελεστές του τμήματος MA του μοντέλου (του μη αναδρομικού γραμμικού φίλτρου), $x(t)$ είναι το στοιχείο (εισόδου) του λευκού θορύβου ενώ το $\varepsilon(t)$ είναι τα ασυσχέτιστα σφάλματα εξόδου.

4. Παρουσίαση και μοντελοποίηση της έρευνας

4.1 Παρουσίαση δεδομένων

Για την υλοποίηση της συγκεκριμένης έρευνας χρειάστηκε να βρεθούν πληροφορίες όσων αφορά τις τιμές των τριών πηγών ενέργειας όπου θα γίνει η πρόβλεψη. Πιο συγκεκριμένα βρέθηκαν βάσεις δεδομένων για το αργό πετρέλαιο, το φυσικό αέριο και τον άνθρακα. Τα δεδομένα αυτά αντλήθηκαν από την ιστοσελίδα Markets Insider και για τις πηγές ενέργειας [Brent Αργό Πετρέλαιο](#), [Henry Hub Φυσικό Αέριο](#) και [Άνθρακα](#). Κάθε βάση δεδομένων αποτελούταν από πέντε στήλες με όνομα Date, Open, Close, High, Low. Η στήλη Date περιέχει την ημερομηνία για την οποία έγινε η ανάρτηση των δεδομένων. Η στήλη Open περιέχει την τιμή ανοίγματος της τιμής της αντίστοιχης τιμής ενέργειας, ενώ η στήλη Close περιέχει την τιμή κλεισίματος της τιμής της αντίστοιχης τιμής ενέργειας. Τέλος οι στήλες High και Low δίνουν την μεγαλύτερη και μικρότερη τιμή αντίστοιχα της τιμής της κάθε πηγής ενέργειας μέσα στην ημέρα. Οι τιμές αυτές αναφέρονται σε αμερικανικά δολάρια ανά βαρέλι (Barrel) όσον αφορά το Αργό Πετρέλαιο, σε αμερικανικά δολάρια ανά εκατομμύριο βρετανικές μονάδες θερμότητας (MMBtu) όσον αφορά το Φυσικό Αέριο και αμερικανικά δολάρια ανά τόνο όσον αφορά τον Άνθρακα. Αξίζει να σημειωθεί ότι οποιαδήποτε μηδενική τιμή φαίνεται στον πίνακα 4.1 αποτελούσε κενή τιμή, η οποία αντικαταστάθηκε με το μηδέν.

Παρακάτω παρουσιάζεται ένας πίνακας ως δείγμα της συνολικής βάσης δεδομένων, ο οποίος αφορά το φυσικό αέριο.

Date	Open	Close	High	Low
03/13/23	2,426	2,452	2,454	2,405
03/14/23	2,624	2,573	2,674	2,53
03/15/23	2,577	2,439	2,595	2,384
03/16/23	2,483	2,514	2,554	2,429
03/17/23	2,527	2,338	2,534	2,327
03/20/23	2,347	2,223	2,427	2,211
03/21/23	2,246	2,348	2,358	2,127
03/22/23	2,322	2,171	2,326	2,152
03/23/23	2,215	2,154	2,261	2,136
03/24/23	2,153	2,216	2,238	2,141
03/27/23	2,13	2,088	2,143	2,059
03/28/23	2,089	2,03	2,122	1,998
03/29/23	2,024	1,991	2,083	1,944
03/30/23	0	2,104	0	2,08
03/31/23	2,107	2,216	2,241	2,074
04/03/23	2,085	2,097	2,16	2,015
04/04/23	2,114	2,106	2,166	2,076

04/05/23	2,096	2,155	2,197	2,065
04/06/23	2,141	2,011	2,181	1,992
04/07/23	0	2,011	0	0
04/10/23	2,019	2,172	2,223	2,011
04/11/23	2,182	2,186	2,247	2,126
04/12/23	2,221	2,093	2,229	2,069
04/13/23	2,084	2,007	2,13	1,995
04/14/23	2,015	2,114	2,132	1,946
04/17/23	2,15	2,275	2,314	2,146
04/18/23	2,29	2,366	2,385	2,229
04/19/23	2,373	2,222	2,383	2,177
04/20/23	2,179	2,249	2,271	2,14
04/21/23	2,192	2,233	2,274	2,164
04/24/23	2,22	2,273	2,286	2,181
04/25/23	2,262	2,307	2,312	2,17
04/26/23	2,239	2,117	2,274	2,101
04/27/23	0	2,355	2,376	2,268
04/28/23	2,358	2,41	2,529	2,285
05/01/23	2,398	2,318	2,41	2,29
05/02/23	2,314	2,214	2,345	2,186


Πίνακας 4.1 Δείγμα Βάσης δεδομένων για το Φυσικό Αέριο

Τα δεδομένα για κάθε πηγή ενέργειας είχαν έναν χρονικό ορίζοντα 10 ετών, όμως λόγω έλλειψης κάποιων καταχωρήσεων παρατηρείται διαφορετικός αριθμός παρατηρήσεων σε κάθε πηγή ενέργειας. Πιο αναλυτικά οι συνολικές καταχωρήσεις για το Brent Αργό Πετρέλαιο αριθμούνται σε 2678, για το Henry Hub Φυσικό Αέριο αριθμούνται σε 2609 και για τον Άνθρακα σε 2638. Για όλες τις πηγές ενέργειας χρησιμοποιήθηκε ως ημερομηνία έναρξης η 02/01/2013 και ως τελική ημερομηνία η 02/05/2023. Από το σύνολο των δεδομένων το 80% χρησιμοποιήθηκε ως σετ εκπαίδευσης και το 20% ως test σετ για όλες τις πηγές ενέργειας.

4.2 Παρουσίαση μοντέλου ANFIS

Στο κεφάλαιο αυτό θα αναλυθεί το μοντέλο ANFIS που χρησιμοποιήθηκε για την συγκεκριμένη έρευνα. Το ασαφές σύστημα αυτό υλοποιήθηκε σε περιβάλλον MATLAB χρησιμοποιώντας το εργαλείο Fuzzy Logic Toolbox. Ως σύστημα ασαφούς συλλογιστικής επιλέχθηκε το μοντέλο Sugeno το οποίο για τις ανάγκες της εργασίας δέχεται μία είσοδο και έχει μία έξοδο. Κάθε είσοδος διαθέτει δύο συναρτήσεις συμμετοχής (Membership Functions), ενώ η έξοδος είναι ένα διάνυσμα με αριθμητικές τιμές. Η μεταβλητή εισόδου που χρησιμοποιήθηκε ήταν η ημερήσια τιμή κλεισίματος

της κάθε πηγής ενέργειας, ενώ ως μεταβλητή εξόδου ήταν πάλι η ημερήσια τιμή κλεισίματος της κάθε πηγής. Οι συναρτήσεις συμμετοχής στην είσοδο είχαν την μορφή της γενικευμένης καμπανοειδούς συνάρτησης συμμετοχής.



System anfis: 1 inputs, 1 outputs, 2 rules

Εικόνα 4.1 Δομή συστήματος ANFIS

4.3 Μέτρα σύγκρισης αποτελεσμάτων

Τόσο το μοντέλο ANFIS όσο και τα υπόλοιπα μοντέλα με τα οποία θα γίνει σύγκριση χρησιμοποιούν κάποια κριτήρια για την αξιολόγηση των αποτελεσμάτων τους. Αυτά τα κριτήρια εκφράζουν κατά πόσο μία πρόβλεψη είναι ακριβής. Στην συγκεκριμένη έρευνα χρησιμοποιήθηκαν τα κριτήρια MSE, RMSE, MAE, MAPE για τα οποία μία μικρή τιμή δηλώνει ικανοποιητική πρόβλεψη, ενώ μία μεγάλη τιμή δηλώνει μη ικανοποιητική. Παρακάτω θα αναλυθούν περαιτέρω τα συγκεκριμένα κριτήρια.

Mean Squared Error (MSE)

Στην στατιστική, το Mean Squared Error (MSE) ή αλλιώς Mean Squared Deviation (MSD) ενός εκτιμητή μετρά τον μέσο όρο των τετραγώνων των σφαλμάτων, δηλαδή τη μέση τετραγωνική διαφορά μεταξύ των εκτιμώμενων τιμών και των πραγματικών.

$$MSE = \frac{1}{N} \cdot \sum_{t=1}^N e_t^2 \quad (42)$$

Όπου e_i είναι η διαφορά της πραγματικής από την προβλεπόμενη τιμή και N ο αριθμός των προβλέψεων.

Root Mean Squared Error (RMSE)

Το Root Mean Squared Error (RMSE) ή αλλιώς Root Mean Squared Deviation (RMSD) ενός εκτιμητή μετρά την τετραγωνική ρίζα του μέσου όρου των τετραγώνων των σφαλμάτων, δηλαδή τη τετραγωνική ρίζα της μέσης τετραγωνικής διαφοράς μεταξύ των εκτιμώμενων τιμών και των πραγματικών. Ουσιαστικά είναι η τετραγωνική ρίζα του MSE.

$$RMSE = \sqrt{\frac{\sum_{t=1}^N e_t^2}{N}} \quad (43)$$

Όπου e_i είναι η διαφορά της πραγματικής από την προβλεπόμενη τιμή και N ο αριθμός των προβλέψεων.

Mean Absolute Error (MAE)

Το Mean Absolute Error (MAE) ενός εκτιμητή μετρά τον μέσο όρο των απόλυτων σφαλμάτων, δηλαδή την μέση απόλυτη διαφορά μεταξύ των εκτιμώμενων τιμών και των πραγματικών.

$$MAE = \frac{1}{N} \cdot \sum_{t=1}^N |e_t| \quad (44)$$

Όπου e_i είναι η διαφορά της πραγματικής από την προβλεπόμενη τιμή και N ο αριθμός των προβλέψεων.

Mean Absolute Percentage Error (MAPE)

Το Mean Absolute Percentage Error (MAPE) ή αλλιώς Mean Absolute Percentage Deviation (MAPD) ενός εκτιμητή μετρά τον μέσο όρο των απόλυτων ποσοστιαίων σφαλμάτων, δηλαδή την μέση απόλυτη ποσοστιαία διαφορά μεταξύ των εκτιμώμενων τιμών και των πραγματικών.


$$MAPE = \frac{100}{N} \cdot \sum_{t=1}^N |e_t| \quad (45)$$

Όπου e_t είναι η διαφορά της πραγματικής από την προβλεπόμενη τιμή και N ο αριθμός των προβλέψεων.

4.4 Παρουσίαση και σχολιασμός των αποτελεσμάτων

Στην συγκεκριμένη έρευνα έγιναν διάφορες δοκιμές όσον αφορά τα αρχικά δεδομένα. Αρχικά έγινε μία προσπάθεια να τροφοδοτηθούν τα μοντέλα με δεδομένα 5 ετών για την κάθε πηγή ενέργειας. Πιο συγκεκριμένα χρησιμοποιήθηκαν οι ημερήσιες τιμές κλεισίματος του Brent Αργού πετρελαίου από 03/01/2017 έως 26/09/2022 (1494 τιμές), του Henry Hub Φυσικού Αερίου από 02/01/2017 έως 10/05/2022 (1446 τιμές) και του Άνθρακα από 03/01/2017 έως 26/09/2022 (1460 τιμές). Παρακάτω θα παρουσιαστούν και θα σχολιασθούν οι προβλέψεις και τα σφάλματα του κάθε μοντέλου για κάθε πηγή ενέργειας για αρχικά δεδομένα 5 ετών. Επίσης αξίζει να σημειωθεί ότι το στην εκπαίδευση του μοντέλου ANFIS χρησιμοποιούνται 1000 εποχές (Epochs).

Brent Αργό Πετρέλαιο για αρχικά δεδομένα 5 ετών.




Σχήμα 4.1 Πραγματικές ημερήσιες τιμές κλεισίματος Brent Αργού Πετρελαίου από 2017 έως 2022

Παρακάτω παρουσιάζεται και ο πίνακας των σφαλμάτων όσον αφορά τα μοντέλα ANFIS, AR και ARMA για τις προβλέψεις που έγιναν για το Brent Αργό Πετρέλαιο με δεδομένα 5 ετών. Όπως αναφέρθηκε παραπάνω ως σφάλματα θα χρησιμοποιηθούν τα MSE, RMSE, MAE και MAPE. Με έντονο μαύρο χρώμα θα παρουσιάζεται το μοντέλο το οποίο έχει τις μικρότερες τιμές σφαλμάτων, άρα και την πιο ακριβή πρόβλεψη.

	ANFIS	AR	ARMA
MSE	13,2225	26,8189	26,8237
RMSE	3,6362	5,1787	5,1791
MAE	2,6852	4,0360	4,0366
MAPE	2,5361	3,8049	3,8054

Πίνακας 4.2 Τιμές σφαλμάτων για το Brent Αργό Πετρέλαιο για αρχικά δεδομένα 5 ετών

Henry Hub Φυσικό Αέριο για αρχικά δεδομένα 5 ετών.




Σχήμα 4.2 Πραγματικές ημερήσιες τιμές κλεισίματος Henry Hub Φυσικού Αερίου από 2017 έως 2022

Παρακάτω παρουσιάζεται και ο πίνακας των σφαλμάτων όσον αφορά τα μοντέλα ANFIS, AR και ARMA για τις προβλέψεις που έγιναν για το Henry Hub Φυσικό Αέριο με δεδομένα 5 ετών. Με έντονο μαύρο χρώμα θα παρουσιάζεται το μοντέλο το οποίο έχει τις μικρότερες τιμές σφαλμάτων, άρα και την πιο ακριβή πρόβλεψη.

	ANFIS	AR	ARMA
MSE	69,7919	0,2682	0,2676
RMSE	8,3541	0,5179	0,5173
MAE	6,6150	0,4034	0,4016
MAPE	80,0786	5,5589	5,5379

Πίνακας 4.3 Τιμές σφαλμάτων για το Henry Hub Φυσικό Αέριο για αρχικά δεδομένα 5 ετών

Άνθρακας για αρχικά δεδομένα 5 ετών.



Σχήμα 4.3 Πραγματικές ημερήσιες τιμές κλεισίματος Άνθρακα από 2017 έως 2022

Παρακάτω παρουσιάζεται και ο πίνακας των σφαλμάτων όσον αφορά τα μοντέλα ANFIS, AR και ARMA για τις προβλέψεις που έγιναν για τον Άνθρακα με δεδομένα 5 ετών. Με έντονο μαύρο χρώμα θα παρουσιάζεται το μοντέλο το οποίο έχει τις μικρότερες τιμές σφαλμάτων, άρα και την πιο ακριβή πρόβλεψη.

	ANFIS	AR	ARMA
MSE	5659,0195	304,4425	305,8577
RMSE	75,2264	17,4482	17,4887
MAE	66,9414	11,4938	11,5184
MAPE	20,3647	3,6052	3,6135

Πίνακας 4.4 Τιμές σφαλμάτων για τον Άνθρακα για αρχικά δεδομένα 5 ετών

Συγκεντρωτικοί πίνακες αποτελεσμάτων όσον αφορά αρχικά δεδομένα 5 ετών.

	ANFIS	AR	ARMA
MSE	13,2225	26,8189	26,8237
RMSE	3,6362	5,1787	5,1791
MAE	2,6852	4,0360	4,0366
MAPE	2,5361	3,8049	3,8054

Πίνακας 4.5 Τιμές σφαλμάτων για το Brent Αργό Πετρέλαιο για αρχικά δεδομένα 5 ετών

	ANFIS	AR	ARMA
MSE	69,7919	0,2682	0,2676
RMSE	8,3541	0,5179	0,5173
MAE	6,6150	0,4034	0,4016
MAPE	80,0786	5,5589	5,5379

Πίνακας 4.6 Τιμές σφαλμάτων για το Henry Hub Φυσικό Αέριο για αρχικά δεδομένα 5 ετών


	ANFIS	AR	ARMA
MSE	5659,0195	304,4425	305,8577
RMSE	75,2264	17,4482	17,4887
MAE	66,9414	11,4938	11,5184
MAPE	20,3647	3,6052	3,6135

Πίνακας 4.7 Τιμές σφαλμάτων για τον Άνθρακα για αρχικά δεδομένα 5 ετών


Από τους παραπάνω πίνακες δεν μπορεί εύκολα να προκύψει κάποιο συμπέρασμα. Πιο συγκεκριμένα καλύτερη πρόβλεψη όσον αφορά το Brent Αργό Πετρέλαιο εμφανίζει το μοντέλο ANFIS, όσον αφορά το Henry Hub Φυσικό Αέριο εμφανίζει το μοντέλο ARMA ενώ για όσον αφορά τον Άνθρακα εμφανίζει το μοντέλο AR. Όμως και στις τρεις περιπτώσεις τον διαφορετικών πηγών ενέργειας για όλα τα μοντέλα εμφανίζονται γενικά μεγάλες τιμές σφαλμάτων, οπότε δεν μπορεί να προκύψει το συμπέρασμα ότι τα μοντέλα αυτά για τον συγκεκριμένο αριθμό δεδομένων είναι αποτελεσματικά. Έτσι παρακάτω θα γίνει μία προσπάθεια μείωσης αυτών των σφαλμάτων.

Όπως παρατηρήθηκε παραπάνω με αρχικά δεδομένα για 5 έτη σε κάθε πηγή ενέργειας δεν μπορεί να προκύψει κάποιο συμπέρασμα καθώς τα σφάλματα που προκύπτουν από τα μοντέλα έχουν αρκετά μεγάλες τιμές. Έτσι έγινε δοκιμή για όλες τις πηγές ενέργειας να χρησιμοποιηθούν αρχικά δεδομένα στα μοντέλα 10 ετών. Πιο συγκεκριμένα χρησιμοποιήθηκαν οι ημερήσιες τιμές κλεισίματος του Brent Αργού πετρελαίου από 02/01/2013 έως 02/05/2023 (2678 τιμές), του Henry Hub Φυσικού Αερίου από 02/01/2013 έως 02/05/2023 (2609 τιμές) και του Άνθρακα από 02/01/2013 έως 02/05/2023 (2638 τιμές). Παρακάτω θα παρουσιαστούν και θα σχολιασθούν οι προβλέψεις και τα σφάλματα του κάθε μοντέλου για κάθε πηγή ενέργειας για αρχικά δεδομένα 10 ετών. Επίσης αξίζει να σημειωθεί ότι το στην εκπαίδευση του μοντέλου ANFIS χρησιμοποιούνται 1000 εποχές (Epochs).

Brent Αργό Πετρέλαιο για αρχικά δεδομένα 10 ετών.




Σχήμα 4.4 Πραγματικές ημερήσιες τιμές κλεισίματος Brent Αργού Πετρελαίου από 2013 έως 2023




Σχήμα 4.5 2-D απεικόνιση της διασποράς των δεδομένων εκπαίδευσης

Στο σχήμα 4.5 παρουσιάζεται η 2-D απεικόνιση της διασποράς των δεδομένων εκπαίδευσης του μοντέλου ANFIS. Γενικά είναι επιθυμητό τα δεδομένα εκπαίδευσης να έχουν μεγάλη διασπορά έτσι ώστε το μοντέλο να μπορεί να συλλάβει καλύτερα της δυναμικές σχέσεις της διαδικασίας. Ιδανικό θα ήταν τα δεδομένα εκπαίδευσης να καλύπτουν όλη την επιφάνεια, κάτι το οποίο δεν συμβαίνει σε αυτήν την περίπτωση.




Σχήμα 4.6 : Η εξέλιξη στην ρίζα του μέσου τετραγωνικού σφάλματος (RMSE) και το βήμα μάθησης (step size) του μοντέλου ANFIS κατά την εκπαίδευση του.


Από το διάγραμμα 4.6 μπορούμε να διαπιστώσουμε ότι δεν υπάρχει βελτίωση στην μάθηση του μοντέλου από την 300^η επανάληψη και μετά . Δηλαδή το μοντέλο δεν θα βελτιωθεί όσες φορές και να εκπαιδευτεί ακόμη. Θα μπορούσε να εξοικονομηθεί υπολογιστικός χρόνος αν σταματούσε η εκπαίδευση στις 300 επαναλήψεις αντί για τις 1000 που έχει οριστεί στην αρχή.



Σχήμα 4.7 : Σχηματική απεικόνιση των συναρτήσεων συμμετοχής του μοντέλου ANFIS πριν την εκπαίδευση του




Σχήμα 4.8 : Σχηματική απεικόνιση των συναρτήσεων συμμετοχής όπως έχουν διαμορφωθεί μετά την εκπαίδευση του μοντέλου ANFIS.




Σχήμα 4.9 Τάση των τιμών του ANFIS σε σχέση με την πραγματική τάση

Στο σχήμα 4.9 παρατηρείται η γραφική απεικόνιση της πρόβλεψης του μοντέλου ANFIS σε σχέση με τις πραγματικές τιμές. Η μπλε γραμμή απεικονίζει τις πραγματικές τιμές του Brent Αργού Πετρελαίου, ενώ η κόκκινη γραμμή απεικονίζει την πρόβλεψη που προέκυψε από το μοντέλο ANFIS. Από το σχήμα αυτό φαίνεται ότι η πρόβλεψη του μοντέλου ANFIS είναι πολύ κοντά στις πραγματικές τιμές. Το μοντέλο έχει καταφέρει να συλλάβει και την τάση των τιμών αυτών. Έτσι η πρόβλεψη καθίσταται αρκετά ικανοποιητική.




Σχήμα 4.10 Γραφική απεικόνιση του σφάλματος πρόβλεψης του μοντέλου ANFIS



Σχήμα 4.11 Τάση των τιμών του AR σε σχέση με την πραγματική τάση

Στο σχήμα 4.11 παρατηρείται η γραφική απεικόνιση της πρόβλεψης του μοντέλου AR σε σχέση με τις πραγματικές τιμές. Η μπλε γραμμή απεικονίζει τις πραγματικές τιμές του Brent Αργού Πετρελαίου, ενώ η κόκκινη γραμμή απεικονίζει την πρόβλεψη που προέκυψε από το μοντέλο AR. Από το σχήμα αυτό φαίνεται ότι η πρόβλεψη του μοντέλου AR είναι αρκετά κοντά στις πραγματικές τιμές, δηλαδή το μοντέλο συλλαμβάνει την σωστή τάση των τιμών αυτών.



Σχήμα 4.12 Τάση των τιμών του ARMA σε σχέση με την πραγματική τάση


Στο σχήμα 4.12 παρατηρείται η γραφική απεικόνιση της πρόβλεψης του μοντέλου ARMA σε σχέση με τις πραγματικές τιμές. Η μπλε γραμμή απεικονίζει τις πραγματικές τιμές του Brent Αργού Πετρελαίου, ενώ η κόκκινη γραμμή απεικονίζει την πρόβλεψη που προέκυψε από το μοντέλο ARMA. Από το σχήμα αυτό φαίνεται ότι η πρόβλεψη του μοντέλου ARMA είναι αρκετά κοντά στις πραγματικές τιμές, δηλαδή το μοντέλο συλλαμβάνει την σωστή τάση των τιμών αυτών.

Παρακάτω παρουσιάζεται και ο πίνακας των σφαλμάτων όσον αφορά τα μοντέλα ANFIS, AR και ARMA για τις προβλέψεις που έγιναν για το Brent Αργό Πετρέλαιο με δεδομένα 10 ετών. Όπως αναφέρθηκε παραπάνω ως σφάλματα θα χρησιμοποιηθούν τα MSE, RMSE, MAE και MAPE. Με έντονο μαύρο χρώμα θα παρουσιάζεται το μοντέλο το οποίο έχει τις μικρότερες τιμές σφαλμάτων, άρα και την πιο ακριβή πρόβλεψη.


	ANFIS	AR	ARMA
MSE	5,4685	11,5155	11,5044
RMSE	2,3384	3,3934	3,3918
MAE	1,8313	2,6794	2,6794
MAPE	1,9471	2,8599	2,8603

Πίνακας 4.8 Τιμές σφαλμάτων για το Brent Αργό Πετρέλαιο για αρχικά δεδομένα 10 ετών

Henry Hub Φυσικό Αέριο για αρχικά δεδομένα 10 ετών.




Σχήμα 4.13 Πραγματικές ημερήσιες τιμές κλεισίματος Henry Hub Φυσικού Αερίου από 2013 έως 2023




Σχήμα 4.14 2-D απεικόνιση της διασποράς των δεδομένων εκπαίδευσης

Στο σχήμα 4.14 παρουσιάζεται η 2-D απεικόνιση της διασποράς των δεδομένων εκπαίδευσης του μοντέλου ANFIS. Γενικά είναι επιθυμητό τα δεδομένα εκπαίδευσης να έχουν μεγάλη διασπορά έτσι ώστε το μοντέλο να μπορεί να συλλάβει καλύτερα της δυναμικές σχέσεις της διαδικασίας. Παρατηρούμε σε αυτήν την περίπτωση ότι τα δεδομένα εκπαίδευσης έχουν μεγαλύτερη διασπορά από ότι είχαν τα δεδομένα εκπαίδευσης στην περίπτωση του Brent Αργού Πετρελαίου. Βέβαια και σε αυτήν την περίπτωση ιδανικό θα ήταν τα δεδομένα εκπαίδευσης να καλύπτουν όλη την επιφάνεια, κάτι το οποίο δεν συμβαίνει.




Σχήμα 4.15 : Η εξέλιξη στην ρίζα του μέσου τετραγωνικού σφάλματος (RMSE) και το βήμα μάθησης (step size) του μοντέλου ANFIS κατά την εκπαίδευση του.


Από το διάγραμμα 4.15 μπορούμε να διαπιστώσουμε ότι υπάρχει πιθανότητα να υπήρχε βελτίωση του σφάλματος αν υπήρχαν περισσότερες επαναλήψεις εκπαίδευσης. Αυτό φαίνεται από το ότι η γραφική απεικόνιση στο υποδιάγραμμα ANFIS step size curve δεν έχει φτάσει στην τιμή 0. Οπότε σε αυτήν την περίπτωση μία αύξηση των εποχών μπορεί να είχε ως αποτέλεσμα μικρότερες τιμές σφαλμάτων.



Σχήμα 4.16 : Σχηματική απεικόνιση των συναρτήσεων συμμετοχής του μοντέλου ANFIS πριν την εκπαίδευση του




Σχήμα 4.17 : Σχηματική απεικόνιση των συναρτήσεων συμμετοχής όπως έχουν διαμορφωθεί μετά την εκπαίδευση του μοντέλου ANFIS.




Σχήμα 4.18 Τάση των τιμών του ANFIS σε σχέση με την πραγματική τάση

Στο σχήμα 4.18 παρατηρείται η γραφική απεικόνιση της πρόβλεψης του μοντέλου ANFIS σε σχέση με τις πραγματικές τιμές. Η μπλε γραμμή απεικονίζει τις πραγματικές τιμές του Henry Hub Φυσικού Αερίου, ενώ η κόκκινη γραμμή απεικονίζει την πρόβλεψη που προέκυψε από το μοντέλο ANFIS. Από το σχήμα αυτό φαίνεται ότι η πρόβλεψη του μοντέλου ANFIS είναι πολύ κοντά στις πραγματικές τιμές. Το μοντέλο έχει καταφέρει να συλλάβει και την τάση των τιμών αυτών. Έτσι η πρόβλεψη καθίσταται αρκετά ικανοποιητική.




Σχήμα 4.19 Γραφική απεικόνιση του σφάλματος πρόβλεψης του μοντέλου ANFIS



Σχήμα 4.20 Τάση των τιμών του AR σε σχέση με την πραγματική τάση

Στο σχήμα 4.20 παρατηρείται η γραφική απεικόνιση της πρόβλεψης του μοντέλου AR σε σχέση με τις πραγματικές τιμές. Η μπλε γραμμή απεικονίζει τις πραγματικές τιμές του Henry Hub Φυσικού Αερίου, ενώ η κόκκινη γραμμή απεικονίζει την πρόβλεψη που προέκυψε από το μοντέλο AR. Από το σχήμα αυτό φαίνεται ότι η πρόβλεψη του μοντέλου AR είναι αρκετά κοντά στις πραγματικές τιμές, δηλαδή το μοντέλο συλλαμβάνει την σωστή τάση των τιμών αυτών.



Σχήμα 4.21 Τάση των τιμών του ARMA σε σχέση με την πραγματική τάση


Στο σχήμα 4.21 παρατηρείται η γραφική απεικόνιση της πρόβλεψης του μοντέλου ARMA σε σχέση με τις πραγματικές τιμές. Η μπλε γραμμή απεικονίζει τις πραγματικές τιμές του Henry Hub Φυσικού Αερίου, ενώ η κόκκινη γραμμή απεικονίζει την πρόβλεψη που προέκυψε από το μοντέλο ARMA. Από το σχήμα αυτό φαίνεται ότι η πρόβλεψη του μοντέλου ARMA είναι αρκετά κοντά στις πραγματικές τιμές, δηλαδή το μοντέλο συλλαμβάνει την σωστή τάση των τιμών αυτών.

Παρακάτω παρουσιάζεται και ο πίνακας των σφαλμάτων όσον αφορά τα μοντέλα ANFIS, AR και ARMA για τις προβλέψεις που έγιναν για το Henry Hub Φυσικό Αέριο με δεδομένα 10 ετών. Με έντονο μαύρο χρώμα θα παρουσιάζεται το μοντέλο το οποίο έχει τις μικρότερες τιμές σφαλμάτων, άρα και την πιο ακριβή πρόβλεψη.


	ANFIS	AR	ARMA
MSE	0,1268	0,2094	0,2085
RMSE	0,3561	0,4576	0,4566
MAE	0,2732	0,3362	0,3339
MAPE	4,7567	6,0186	5,9831

Πίνακας 4.9 Τιμές σφαλμάτων για το Henry Hub Φυσικό Αέριο για αρχικά δεδομένα 10 ετών

Άνθρακας για αρχικά δεδομένα 10 ετών.




Σχήμα 4.22 Πραγματικές ημερήσιες τιμές κλεισίματος του Άνθρακα από 2013 έως 2023




Σχήμα 4.23 2-D απεικόνιση της διασποράς των δεδομένων εκπαίδευσης

Στο σχήμα 4.23 παρουσιάζεται η 2-D απεικόνιση της διασποράς των δεδομένων εκπαίδευσης του μοντέλου ANFIS. Γενικά είναι επιθυμητό τα δεδομένα εκπαίδευσης να έχουν μεγάλη διασπορά έτσι ώστε το μοντέλο να μπορεί να συλλάβει καλύτερα της δυναμικές σχέσεις της διαδικασίας. Παρατηρούμε σε αυτήν την περίπτωση ότι τα δεδομένα εκπαίδευσης έχουν πολύ μικρή διασπορά καθώς τα περισσότερα είναι μαζεμένα στην αρχή της επιφάνειας. Έτσι θα μπορούσε κανείς να παρατηρήσει ότι έχουν μικρότερη διασπορά και από τα δεδομένα εκπαίδευσης του Brent Αργού πετρελαίου και από του Henry Hub Φυσικού Αερίου. Βέβαια και σε αυτήν την περίπτωση ιδανικό θα ήταν τα δεδομένα εκπαίδευσης να καλύπτουν όλη την επιφάνεια, κάτι το οποίο δεν συμβαίνει.




Σχήμα 4.24 : Η εξέλιξη στην ρίζα του μέσου τετραγωνικού σφάλματος (RMSE) και το βήμα μάθησης (step size) του μοντέλου ANFIS κατά την εκπαίδευση του.


Από το διάγραμμα 4.24 μπορούμε να διαπιστώσουμε ότι υπάρχει πιθανότητα να υπήρχε βελτίωση του σφάλματος αν υπήρχαν περισσότερες επαναλήψεις εκπαίδευσης. Αυτό φαίνεται από το ότι η γραφική απεικόνιση στο υποδιάγραμμα ANFIS step size curve δεν έχει φτάσει στην τιμή 0. Οπότε σε αυτήν την περίπτωση μία αύξηση των εποχών μπορεί να είχε ως αποτέλεσμα μικρότερες τιμές σφαλμάτων.



Σχήμα 4.25 : Σχηματική απεικόνιση των συναρτήσεων συμμετοχής του μοντέλου ANFIS πριν την εκπαίδευση του




Σχήμα 4.26 :Σχηματική απεικόνιση των συναρτήσεων συμμετοχής όπως έχουν διαμορφωθεί μετά την εκπαίδευση του μοντέλου ANFIS




Σχήμα 4.27 Τάση των τιμών του ANFIS σε σχέση με την πραγματική τάση

Στο σχήμα 4.27 παρατηρείται η γραφική απεικόνιση της πρόβλεψης του μοντέλου ANFIS σε σχέση με τις πραγματικές τιμές. Η μπλε γραμμή απεικονίζει τις πραγματικές τιμές του Άνθρακα, ενώ η κόκκινη γραμμή απεικονίζει την πρόβλεψη που προέκυψε από το μοντέλο ANFIS. Από το σχήμα αυτό φαίνεται ότι η πρόβλεψη του μοντέλου ANFIS είναι πολύ κοντά στις πραγματικές τιμές. Το μοντέλο έχει καταφέρει να συλλάβει και την τάση των τιμών αυτών. Έτσι η πρόβλεψη καθίσταται αρκετά ικανοποιητική.




Σχήμα 4.28 Γραφική απεικόνιση του σφάλματος πρόβλεψης του μοντέλου ANFIS



Σχήμα 4.29 Τάση των τιμών του AR σε σχέση με την πραγματική τάση

Στο σχήμα 4.29 παρατηρείται η γραφική απεικόνιση της πρόβλεψης του μοντέλου AR σε σχέση με τις πραγματικές τιμές. Η μπλε γραμμή απεικονίζει τις πραγματικές τιμές του Άνθρακα, ενώ η κόκκινη γραμμή απεικονίζει την πρόβλεψη που προέκυψε από το μοντέλο AR. Από το σχήμα αυτό φαίνεται ότι η πρόβλεψη του μοντέλου AR είναι αρκετά κοντά στις πραγματικές τιμές, δηλαδή το μοντέλο συλλαμβάνει την σωστή τάση των τιμών αυτών.



Σχήμα 4.30 Τάση των τιμών του ARMA σε σχέση με την πραγματική τάση

Στο σχήμα 4.30 παρατηρείται η γραφική απεικόνιση της πρόβλεψης του μοντέλου ARMA σε σχέση με τις πραγματικές τιμές. Η μπλε γραμμή απεικονίζει τις πραγματικές τιμές του Άνθρακα, ενώ η κόκκινη γραμμή απεικονίζει την πρόβλεψη που προέκυψε από το μοντέλο ARMA. Από το σχήμα αυτό φαίνεται ότι η πρόβλεψη του μοντέλου ARMA είναι αρκετά κοντά στις πραγματικές τιμές, δηλαδή το μοντέλο συλλαμβάνει την σωστή τάση των τιμών αυτών.

Παρακάτω παρουσιάζεται και ο πίνακας των σφαλμάτων όσον αφορά τα μοντέλα ANFIS, AR και ARMA για τις προβλέψεις που έγιναν για τον Άνθρακα με δεδομένα 10 ετών. Με έντονο μαύρο χρώμα θα παρουσιάζεται το μοντέλο το οποίο έχει τις μικρότερες τιμές σφαλμάτων, άρα και την πιο ακριβή πρόβλεψη.

	ANFIS	AR	ARMA
MSE	114,3564	192,2461	193,2403
RMSE	10,6937	13,8652	13,9010
MAE	7,0992	8,8596	8,8950
MAPE	2,7591	3,6324	3,6490

Πίνακας 4.10 Τιμές σφαλμάτων για τον Άνθρακα για αρχικά δεδομένα 10 ετών.

Συγκεντρωτικοί πίνακες αποτελεσμάτων όσον αφορά αρχικά δεδομένα 5 ετών.

	ANFIS	AR	ARMA
MSE	5,4685	11,5155	11,5044
RMSE	2,3384	3,3934	3,3918
MAE	1,8313	2,6794	2,6794
MAPE	1,9471	2,8599	2,8603

Πίνακας 4.11 Τιμές σφαλμάτων για το Brent Αργό Πετρέλαιο για αρχικά δεδομένα 10 ετών

	ANFIS	AR	ARMA
MSE	0,1268	0,2094	0,2085
RMSE	0,3561	0,4576	0,4566
MAE	0,2732	0,3362	0,3339
MAPE	4,7567	6,0186	5,9831

Πίνακας 4.12 Τιμές σφαλμάτων για το Henry Hub Φυσικό Αέριο για αρχικά δεδομένα 10 ετών

	ANFIS	AR	ARMA
MSE	114,3564	192,2461	193,2403
RMSE	10,6937	13,8652	13,9010
MAE	7,0992	8,8596	8,8950
MAPE	2,7591	3,6324	3,6490

Πίνακας 4.13 Τιμές σφαλμάτων για τον Άνθρακα για αρχικά δεδομένα 10 ετών.

Από τους παραπάνω πίνακες, σε αντίθεση με αυτούς για αρχικά δεδομένα 5 ετών, μπορεί πλέον να προκύψει ένα συμπέρασμα. Παρατηρείται ότι οι τιμές των σφαλμάτων είναι αρκετά μικρότερες από αυτές που προκύπτουν από τα μοντέλα που έχουν ως αρχικά δεδομένα αυτά των 5 ετών. Γενικά τα σφάλματα έχουν αρκετά μικρές τιμές και έτσι μπορεί να προκύψει το συμπέρασμα ότι το μοντέλο ANFIS, αφού έχει τις μικρότερες τιμές σφαλμάτων από όλα τα μοντέλα που συγκρίθηκε και για όλες τις πηγές ενέργειας, είναι ικανό ώστε να χρησιμοποιηθεί στην πρόβλεψη τέτοιων τιμών ενέργειας και μάλιστα με πολύ αξιόπιστα αποτελέσματα.

5.Συμπεράσματα

Τα ευρήματα αυτής της έρευνας υπογραμμίζουν τη σημασία της ακριβούς πρόβλεψης των τιμών της ενέργειας για πολλούς ενδιαφερόμενους φορείς, συμπεριλαμβανομένων των παραγωγών ενέργειας, των καταναλωτών και των επενδυτών. Οι ακριβείς προβλέψεις επιτρέπουν στους ενδιαφερόμενους να λαμβάνουν τεκμηριωμένες αποφάσεις, να βελτιστοποιούν την κατανομή των πόρων, να μετριάζουν τους κινδύνους και να κεφαλαιοποιούν τις ευκαιρίες της αγοράς. Αξίζει να σημειωθεί ότι η πρόβλεψη των τιμών της ενέργειας παραμένει ένα δύσκολο έργο λόγω της εγγενούς αστάθειας και απρόβλεπτης κατάστασης των αγορών ενέργειας. Παράγοντες όπως ξαφνικές διακοπές στην παραγωγή, ρυθμιστικές αλλαγές και τεχνολογικές εξελίξεις μπορούν να δημιουργήσουν σημαντικές αβεβαιότητες. Ως εκ τούτου, η συνεχής έρευνα και καινοτομία είναι απαραίτητες για τη βελτίωση των υφιστάμενων μοντέλων, τη διερεύνηση νέων προσεγγίσεων και την προσαρμογή στο εξελισσόμενο ενεργειακό τοπίο.

Πιο συγκεκριμένα αυτή η έρευνα διερεύνησε την αποτελεσματικότητα τριών δημοφιλών μοντέλων στην πρόβλεψη της τιμής της ενέργειας. Τα τρία αυτά μοντέλα ήταν το Adaptive Neuro-Fuzzy Inference System (ANFIS), το AutoRegressive (AR) και το AutoRegressive Moving Average (ARMA). Με τη διεξαγωγή μιας εις βάθος ανάλυσης και σύγκρισης αυτών των μοντέλων, έχουν αποκτηθεί πολύτιμες γνώσεις σχετικά με τις προγνωστικές τους ικανότητες και την απόδοσή τους. Τα αποτελέσματα που προέκυψαν δείχνουν ότι το ANFIS παρουσιάζει αξιοσημείωτες δυνατότητες στην πρόβλεψη των τιμών της ενέργειας. Αξιοποιώντας την ικανότητά του να καταγράφει σύνθετες μη γραμμικές σχέσεις, το ANFIS ξεπέρασε τις επιδόσεις τόσο του μοντέλου AR όσο και του ARMA ως προς την ακρίβεια και την προγνωστική ισχύ. Το ασαφές σύστημα συμπερασμάτων που ενσωματώνεται στο ANFIS επιτρέπει την ενσωμάτωση ειδικών γνώσεων και γλωσσικών μεταβλητών, ενισχύοντας την προσαρμοστικότητα και την ευρωστία του μοντέλου. Ωστόσο, είναι αξιοσημείωτη η απόδοση των μοντέλων AR και ARMA. Αυτά τα παραδοσιακά μοντέλα χρονοσειρών παρουσίασαν αξιόπαινη απόδοση στην αποτύπωση γραμμικών προτύπων και βραχυπρόθεσμων εξαρτήσεων στα δεδομένα τιμών ενέργειας. Παρά τη σχετική απλότητά τους σε σύγκριση με το ANFIS, εξακολουθούν να αποδίδουν ικανοποιητικά αποτελέσματα, ειδικά όταν τα δεδομένα παρουσιάζουν γραμμική συμπεριφορά.

Τα ευρήματα αυτής της έρευνας συναντούν κάποιους περιορισμούς. Τα μοντέλα που χρησιμοποιήθηκαν βασίζονται στην παραδοχή ότι η προβλεπόμενη τιμή της κάθε πηγής ενέργειας θα εξαρτηθεί μόνο από τις ημερήσιες τιμές κλεισίματος. Ωστόσο, όπως φαίνεται και στην βιβλιογραφία, η ενσωμάτωση εξωτερικών παραγόντων, όπως τα εποχιακά μοτίβα, τα γεωπολιτικά γεγονότα, η δυναμική προσφοράς-ζήτησης και η διείσδυση των ανανεώσιμων πηγών ενέργειας, έχει αποδειχθεί ότι ενισχύει τις προγνωστικές ικανότητες των μοντέλων.

Επιπλέον, αξίζει να σημειωθεί ότι η αποτελεσματικότητα κάθε μοντέλου μπορεί να ποικίλλει ανάλογα με τα συγκεκριμένα χαρακτηριστικά και τη δυναμική της υπό εξέταση αγοράς ενέργειας. Ως εκ τούτου, είναι σημαντικό να αξιολογηθεί προσεκτικά

το πλαίσιο και να γίνει μια ενημερωμένη επιλογή του κατάλληλου μοντέλου με βάση το σύνολο δεδομένων και τους στόχους της εργασίας πρόβλεψης.

Συμπερασματικά, αυτή η έρευνα παρέχει πολύτιμες πληροφορίες για την πρόβλεψη των τιμών της ενέργειας χρησιμοποιώντας μοντέλα ANFIS, AR και ARMA. Ενώ το ANFIS επιδεικνύει ανώτερες προγνωστικές ικανότητες, τα μοντέλα AR και ARMA παραμένουν βιώσιμες επιλογές, ιδιαίτερα σε σενάρια όπου τα δεδομένα παρουσιάζουν γραμμικά μοτίβα. Μελλοντικά θα μπορούσε να υλοποιηθεί έρευνα η οποία θα διερευνήσει υβριδικά μοντέλα που συνδυάζουν τα πλεονεκτήματα των παραπάνω προσεγγίσεων για να ενισχύσουν περαιτέρω την ακρίβεια και την αξιοπιστία της πρόβλεψης των τιμών της ενέργειας. Η εφαρμογή αυτών των μοντέλων μπορεί να συμβάλει σε μεγάλο βαθμό στη λήψη αποφάσεων, τη διαχείριση κινδύνων και τον στρατηγικό σχεδιασμό στον ενεργειακό τομέα.

6.Βιβλιογραφία

1. George S. Atsalakis (2014). *Agriculture Commodity Prices Forecasting Using a Fuzzy Inference System*. Agricultural Cooperative Management and Policy. pp 353–3680.
2. George S. Atsalakis (2016). *Using computational intelligence to forecast carbon prices*. Applied Soft Computing. Volume 43, Pages 107-116.
3. George S. Atsalakis, Dimitrios Frantzis, Constantin Zopounidis (2014). *Forecasting carbon emissions by ANFIS*. Journal of Energy Markets 8(3), 55–68.
4. Atsalakis, G., Nezis, D., & Zopounidis, C. (2009). *Neuro-fuzzy versus traditional models for forecasting the wind energy production*. In Skiadas, C. (Ed). Advances in data analysis, statistics for industry (pp. 279-291). Birkhauser Boston: Springer.
5. Atsalakis, G., & Ucenic, C., (2006). *Forecasting the electricity demand using a neuro- fuzzy approach versus traditional methods*. WSEAS Transactions on Business and Economics, 3(1), 9-17.
6. Wen Xie, Lean Yu, Shanying Xu, and Shouyang Wang (2006). *A New Method for Crude Oil Price Forecasting Based on Support Vector Machines*.
7. Yang Zhao, Lean Yu, και Jianping Li (2017). *A deep learning ensemble approach for crude oil price forecasting*. Energy Economics, Volume 66, 9-16.
8. Md Shabbir Alam, Muntasir Murshed, Palanisamy Manigandan, Duraisamy Pachiyappan, Shamansurova Zilola Abduvaxitovna (2023). *Forecasting oil, coal, and natural gas prices in the pre-and post-COVID scenarios: Contextual evidence from India using time series forecasting tools*. Resources Policy, Volume 81, 103342.
9. Jianliang Wang, Changran Lei, Meiyu Guo (2020). *Daily natural gas price forecasting by a weighted hybrid data-driven model*. Journal of Petroleum Science and Engineering, Volume 192, 107240.
10. Ahmed Bouteska, Petr Hajek, Ben Fisher, Mohammad Zoynul Abedin (2023). *Nonlinearity in forecasting energy commodity prices: Evidence from a focused time-delayed neural network*. Research in International Business and Finance, Volume 64, 101863.
11. Gabriel Paes Herrera, Michel Constantino, Benjamin Miranda Tabak, Hemerson Pistori, Jen-Je Su, Athula Naranpanawa (2019). *Long-term forecast*

- of energy commodities price using machine learning*. Energy, Volume 179, Pages 214-221.
12. Moting Su, Zongyi Zhang, Ye Zhu, Donglan Zha (2019). *Data-Driven Natural Gas Spot Price Forecasting with Least Squares Regression Boosting Algorithm*. Energies 2019, 12(6), 1094.
 13. Ioannis E. Livieris, Emmanuel Pintelas, Niki Kiriakidou, Stavros Stavroyiannis (2020). *An Advanced Deep Learning Model for Short-Term Forecasting U.S. Natural Gas Price and Movement*. Artificial Intelligence Applications and Innovations. AIAI 2020 IFIP WG 12.5 International Workshops. pp 165–176.
 14. Zakaria Alameer, Ahmed Fathalla, Kenli Li, Haiwang Ye, Zhang Jianhua (2020). *Multistep-ahead forecasting of coal prices using a hybrid deep learning model*. Resources Policy, Volume 65, 101588.
 15. Quang Hung Do (2020). *Development of MI-ANFIS-BBO Model for Forecasting Crude Oil Price*. Reliability and Statistical Computing pp 167–191.
 16. Rana Abdullah Ahmed, Ani Shabri (2014). *Daily crude oil price forecasting model using arima, generalized autoregressive conditional heteroscedastic and Support Vector Machines*. American Journal of Applied Sciences 11, 425-432
 17. Ali Ghaffari, Samaneh Zare (2009). *A novel algorithm for prediction of crude oil price variation based on soft computing*. Energy Economics, Volume 31, Issue 4, Pages 531-536
 18. Hossein Mombeini, Abdolreza Yazdani-Chamzini (2014). *Developing a new approach for forecasting the trends of oil price*. The Business & Management Review, Volume 4 Number 3.
 19. Shambulingappa H S (2020). *Crude Oil Price Forecasting Using Machine Learning*. International Journal of Advanced Scientific Inovation, Volume 01 Issue 01.
 20. Mohamed Abd Elaziz, Ahmed A. Ewees, Zakaria Alameer (2020). *Improving Adaptive Neuro-Fuzzy Inference System Based on a Modified Salp Swarm Algorithm Using Genetic Algorithm to Forecast Crude Oil Price*. Natural Resources Research 29, pages2671–2686.
 21. Ehsan Lotfi, M R Karimi (2014). *Opec Oil Price Prediction Using Anfis*. Journal of Mathematics and Computer Science, Volume 10, Issue 4, pp 286-296.
 22. Shenghua Xiong, Chunfeng Wang, Zhenming Fang, Dan Ma (2019). *Multi-Step-Ahead Carbon Price Forecasting Based on Variational Mode*

- Decomposition and Fast Multi-Output Relevance Vector Regression Optimized by the Multi-Objective Whale Optimization Algorithm*. Energies 2019, 12(1), 147.
23. Shouyang Wang, Lean Yu, K.K. Lai (2004). *A Novel Hybrid AI System Framework for Crude Oil Price Forecasting*. CASDMKM 2004, LNAI 3327, pp. 233–242.
 24. Yu-Xi Wu, Qing-Biao Wu, Jia-Qi Zhu (2019). *Improved EEMD-based crude oil price forecasting using LSTM networks*. Physica A: Statistical Mechanics and its Applications, Volume 516, Pages 114-124.
 25. Lean Yu, , Xun Zhang, Shouyang Wang (2017). *Assessing Potentiality of Support Vector Machine Method in Crude Oil Price Forecasting*. EURASIA Journal of Mathematics, Science and Technology Education, Volume 13, Issue 12, 7893-7904.
 26. Ani Shabri, Ruhaidah Samsudin (2014). *Daily Crude Oil Price Forecasting Using Hybridizing Wavelet and Artificial Neural Network Model*. Mathematical Problems in Engineering, Volume 2014.
 27. Ali Safari , Maryam Davallou (2018) .*Oil price forecasting using a hybrid model*. Energy, Volume 148, Pages 49-58.
 28. Yanhui Chen, Kaijian He, Geoffrey K.F. Tso (2017). *Forecasting Crude Oil Prices: a Deep Learning based Model*. Procedia Computer Science, Volume 122, Pages 300-307.
 29. Prasannavenkatesan Theerthagiri, A. Usha Ruby (2023). *Seasonal learning based ARIMA algorithm for prediction of Brent oil Price trends*. Multimedia Tools and Applications.
 30. Jawaria Nasir, Muhammad Aamir, Zahoor Ul Haq, Shehzad Khan, Muhammad Yusuf Amin, Muhammad Naeem (2023). *A New Approach for Forecasting Crude Oil Prices Based on Stochastic and Deterministic Influences of LMD Using ARIMA and LSTM Models*. IEEE Access, Volume 11.
 31. Sad Wadi Sajid, Mahmudul Hasan, Md. Fazle Rabbi, Mohammad Zoynul Abedin (2023). *An Ensemble LGBM (Light Gradient Boosting Machine) Approach for Crude Oil Price Prediction*. Novel Financial Applications of Machine Learning and Deep Learning, pp 153–165.
 32. Qin Lu, Jingwen Liao, Kechi Chen, Yanhui Liang, Yu Lin (2023). *Predicting Natural Gas Prices Based on a Novel Hybrid Model with Variational Mode Decomposition*. Computational Economics.

33. Jinchao Li, Shaowen Zhu, Qianqian Wu (2019). *Monthly crude oil spot price forecasting using variational mode decomposition*. Energy Economics, Volume 83, Pages 240-253.
34. Lean Yu, Shouyang Wang, Kin Keung Lai (2008). *Forecasting crude oil price with an EMD-based neural network ensemble learning paradigm*. Energy Economics, Volume 30, Issue 5, Pages 2623-2635.
35. Ranran Li, Xiao Song (2023). *A multi-scale model with feature recognition for the use of energy futures price forecasting*. Expert Systems with Applications, Volume 211, 118622.
36. Καυκαλιάς Κωνσταντίνος (2022). *Ασαφές Σύστημα Πρόβλεψης Τουριστικών Αφίξεων, υπό συνθήκες πανδημίας*. Διπλωματική Εργασία. Τμήμα Μηχανικών Παραγωγής και Διοίκησης. Πολυτεχνείο Κρήτης, Χανιά.
37. Παπαδάκης Στυλιανός (2014). *Το νεύρο-ασαφές μοντέλο ANFIS, Πρόβλεψη τιμών συναλλάγματος με νεύρο-ασαφή συστήματα*. Διπλωματική Εργασία. Τμήμα Μηχανικών Παραγωγής και Διοίκησης, Πολυτεχνείο Κρήτης, Χανιά.
38. Πέτρος Π.Γρούμπος. *Στοιχεία της Ασαφούς Λογικής*. Τμήμα Ηλεκτρολόγων Μηχανικών & Τεχνολογίας Υπολογιστών. Πανεπιστήμιο Πατρών.
39. Μαστοροκώστας, Π. (2015). *Εισαγωγή στην ασαφή λογική – ασαφή σύνολα – συναρτήσεις συμμετοχής* [Κεφάλαιο]. Κάλλιπος, Ανοικτές Ακαδημαϊκές Εκδόσεις.
40. Βακούλη Αντιγόνη (2009). *Ασυνέπειες της ασαφούς λογικής*. Διπλωματική Εργασία. Τμήμα Μηχανικών Παραγωγής και Διοίκησης. Πολυτεχνείο Κρήτης, Χανιά.
41. Παπαδάκης Στέλιος, Αδαμίδης Παναγιώτης (2004). *Ασαφή Συστήματα*. Θεωρία και Εργαστηριακές Ασκήσεις. Τμήμα Πληροφορικής. Τ.Ε.Ι Θεσσαλονίκης.
42. Βασίλειος Καμπουρλάζος, Γεώργιος Παπακώστας. *Εισαγωγή στην Υπολογιστική Νοημοσύνη*. Τμήμα Μηχανικών Πληροφορικής Τ.Ε.. Τ.Ε.Ι Ανατολικής Μακεδονίας και Θράκης.
43. Jyh-Shing, Roger Jang (1993). *ANFIS: Adaptive-Network-Based Fuzzy Inference System*. IEEE Transactions on Systems, Man and Cybernetics, Volume 23