

**ΠΑΝΕΠΙΣΤΗΜΙΟ ΘΕΣΣΑΛΙΑΣ**  
**ΣΧΟΛΗ ΘΕΤΙΚΩΝ ΕΠΙΣΤΗΜΩΝ**  
**ΔΙΑΤΜΗΜΑΤΙΚΟ ΜΕΤΑΠΤΥΧΙΑΚΟ ΠΡΟΓΡΑΜΜΑ**  
**ΠΛΗΡΟΦΟΡΙΚΗ ΚΑΙ ΥΠΟΛΟΓΙΣΤΙΚΗ ΒΙΟΙΑΤΡΙΚΗ**

**«ΠΛΗΡΟΦΟΡΙΚΗ ΜΕ ΕΦΑΡΜΟΓΕΣ ΣΤΗΝ ΑΣΦΑΛΕΙΑ, ΔΙΑΧΕΙΡΙΣΗ  
ΜΕΓΑΛΟΥ ΟΓΚΟΥ ΔΕΔΟΜΕΝΩΝ ΚΑΙ ΠΡΟΣΟΜΟΙΩΣΗ»**



**ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ**

**«Η Τεχνητή Νοημοσύνη και η Προγνωστική Ανάλυση σε Περιβάλλοντα  
Cloud στον Χρηματοοικονομικό Τομέα»**

**ΜΠΙΣΜΠΙΓΙΑΝΝΗΣ ΝΙΚΟΛΑΟΣ**

**Επιβλέπων Καθηγητής: κ. Κολομβάτσος Κωνσταντίνος**

**Λαμία, Φεβρουάριος 2026**

## ΠΕΡΙΛΗΨΗ

Η ραγδαία εξέλιξη της τεχνολογίας και η υιοθέτηση του Υπολογιστικού Νέφους (Cloud Computing) έχουν μετασχηματίσει τον χρηματοοικονομικό τομέα, επιτρέποντας την επεξεργασία δεδομένων μεγάλης κλίμακας και την εφαρμογή προηγμένων μεθόδων Τεχνητής Νοημοσύνης (Artificial Intelligence). Η παρούσα διπλωματική εργασία εξετάζει τον ρόλο της Μηχανικής Μάθησης και της Προγνωστικής Ανάλυσης στη λήψη στρατηγικών αποφάσεων, εστιάζοντας στις προκλήσεις της πρόβλεψης χρηματοοικονομικών χρονοσειρών.

Ως πρακτική εφαρμογή (Case Study), αναπτύχθηκε και αξιολογήθηκε ένα σύστημα πρόβλεψης της τιμής του χρυσού, το οποίο αξιοποιεί μακροοικονομικά δεδομένα της Τράπεζας της Ελλάδος (επιτόκια, πληθωρισμός). Για την υλοποίηση του συστήματος, σχεδιάστηκαν και συγκρίθηκαν καινοτόμες αρχιτεκτονικές Νευρωνικών Δικτύων της οικογένειας xLSTM (Extended LSTM), συγκεκριμένα τα μοντέλα sLSTM (Scalar) και mLSTM (Matrix), έναντι του παραδοσιακού LSTM και κλασικών στατιστικών μεθόδων.

Τα πειραματικά αποτελέσματα κατέδειξαν ότι τα ελληνικά μακροοικονομικά δεδομένα έχουν υψηλή προγνωστική αξία για την πορεία του χρυσού. Επιπλέον, η αρχιτεκτονική mLSTM (Matrix Memory) πέτυχε την υψηλότερη ακρίβεια στην πρόβλεψη τιμής, ξεπερνώντας σημαντικά τη Γραμμική Παλινδρόμηση, η οποία αδυνατεί να μοντελοποιήσει τις μη-γραμμικές συσχετίσεις της αγοράς. Αντίθετα, σε απλούστερα προβλήματα πρόβλεψης τάσης (binary classification), οι κλασικές στατιστικές μέθοδοι (Logistic Regression) παρέμειναν ανταγωνιστικές. Η εργασία καταλήγει στο συμπέρασμα ότι η χρήση Deep Learning με μνήμη πινάκων (Matrix Memory) αποτελεί την βέλτιστη λύση για σύνθετα προβλήματα πρόβλεψης σε ευμετάβλητες αγορές.

**Λέξεις-Κλειδιά:** Τεχνητή Νοημοσύνη, Προγνωστική Ανάλυση, xLSTM, Χρυσός, Cloud Computing, Χρονοσειρές.

## ABSTRACT

The rapid evolution of technology and the adoption of Cloud Computing have transformed the financial sector, enabling large-scale data processing and the application of advanced Artificial Intelligence methods. This thesis examines the role of Machine Learning and Predictive Analytics in strategic decision-making, focusing on the challenges of financial time series forecasting.

As a practical application (Case Study), a gold price forecasting system was developed and evaluated, utilizing macroeconomic data from the Bank of Greece (interest rates, inflation). For the system's implementation, innovative Neural Network architectures of the xLSTM (Extended LSTM) family, specifically sLSTM (Scalar) and mLSTM (Matrix) models, were designed and compared against traditional LSTM and classical statistical methods.

Experimental results demonstrated that Greek macroeconomic data possess high predictive value for gold trends. Furthermore, the mLSTM (Matrix Memory) architecture achieved the highest accuracy in price prediction, significantly outperforming Linear Regression, which fails to model the market's non-linear correlations. Conversely, in simpler trend prediction problems (binary classification), classical statistical methods (Logistic Regression) remained competitive. The thesis concludes that using Deep Learning with Matrix Memory constitutes the optimal solution for complex forecasting problems in volatile markets.

**Keywords:** Artificial Intelligence, Predictive Analytics, xLSTM, Gold Price, Cloud Computing, Time Series.

## Περιεχόμενα

ΠΕΡΙΛΗΨΗ.....	1
ABSTRACT.....	2
Κεφάλαιο 1 – Εισαγωγή.....	6
1.1 Κίνητρο .....	6
1.2 Σκοπός της Εργασίας.....	6
1.3 Ερευνητικά Ερωτήματα.....	7
1.4 Μεθοδολογία .....	7
1.5 Δομή της Εργασίας .....	8
1.6 Αναμενόμενη Συνεισφορά.....	8
Κεφάλαιο 2 – Μηχανική Μάθηση και Analytics .....	9
2.1 Εισαγωγή .....	9
2.2 Θεμελιώδεις Έννοιες της Μηχανικής Μάθησης .....	9
2.2.1 Η Επιλογή Μεταξύ Machine Learning και Deep Learning.....	10
2.3 Προγνωστική Ανάλυση (Predictive Analytics).....	11
2.4 Ενσωμάτωση AI και Cloud Computing στα Predictive Analytics .....	12
2.4.1 Συγκριτική Ανάλυση Παρόχων Υπολογιστικού Νέφους .....	12
2.5 Μεθοδολογίες Εξαγωγής Analytics .....	14
2.6 Ο Ρόλος της Τεχνητής Νοημοσύνης στα Financial Analytics .....	14
2.7 Σύγκριση Παραδοσιακών Μεθόδων και Deep Learning .....	15
2.8 Συμπεράσματα .....	16
Κεφάλαιο 3 – Προκλήσεις στον Χρηματοοικονομικό Τομέα .....	17
3.1 Εισαγωγή .....	17
3.2 Διαχείριση και Ποιότητα Δεδομένων .....	17
3.3 Ιδιωτικότητα, Ασφάλεια και Κανονιστική Συμμόρφωση.....	18
3.4 Ανίχνευση Απάτης (Fraud Detection) και Διαχείριση Κινδύνου .....	18
3.5 Ερμηνευσιμότητα και Διαφάνεια των Μοντέλων (Explainable AI).....	19
3.6 Χρησιμοποιούμενοι Αλγόριθμοι και Τεχνικές στον Χρηματοοικονομικό Τομέα .....	20
3.7 Προκλήσεις στην Πρόβλεψη Χρονοσειρών (Time Series Forecasting).....	22
3.8 Τεχνολογικές Τάσεις και Μελλοντικές Κατευθύνσεις .....	22
3.9 Συμπεράσματα .....	23

Κεφάλαιο 4: Σχεδιασμός και Υλοποίηση Συστήματος Πρόβλεψης .....	24
4.1 Επισκόπηση Αρχιτεκτονικής (System Overview) .....	24
4.2 Συλλογή και Προεπεξεργασία Δεδομένων.....	24
4.3 Σχεδιασμός Αλγορίθμων και Καινοτομία .....	26
4.4 Στρατηγική Εκπαίδευσης .....	28
4.5 Περιβάλλον Εκτέλεσης και Χρήση Πόρων Cloud (Cloud Implementation) ..	29
Κεφάλαιο 5 – Πειραματική Αποτίμηση .....	30
5.1 Πείραμα 1: Αξιολόγηση Δεδομένων & Παραμετροποίηση Μνήμης (Baseline Optimization).....	30
5.1.1 Στόχος .....	30
5.1.2 Μέρος A: Σύγκριση Πηγών Δεδομένων (Greek vs Global) .....	30
5.1.3 Μέρος B: Βελτιστοποίηση Μνήμης (12 Months vs 6 Months) .....	31
5.1.4 Συμπέρασμα Πειράματος 1.....	32
5.2 Πείραμα 2: Σύγκριση Επιδόσεων (Standard LSTM vs xLSTM).....	32
5.2.1 Στόχος .....	32
5.2.2 Μεθοδολογία και Υλοποίηση .....	33
5.2.3 Αποτελέσματα .....	33
5.2.4 Τελική Πρόβλεψη.....	35
5.2.5 Συζήτηση.....	35
5.3 Πείραμα 3: Συγκριτική Αξιολόγηση Αρχιτεκτονικών (Standard vs sLSTM vs mLSTM) .....	35
5.3.1 Στόχος .....	35
5.3.2 Μεθοδολογία και Υλοποίηση (Matrix Memory) .....	36
5.3.3 Αποτελέσματα .....	36
5.3.4 Συζήτηση.....	37
5.4 Πείραμα 4: Σύγκριση με Κλασικές Στατιστικές Μεθόδους (AI vs Statistics) .	38
5.4.1 Στόχος .....	38
5.4.2 Μεθοδολογία.....	38
5.4.3 Αποτελέσματα .....	39
5.4.4 Συζήτηση.....	40
Κεφάλαιο 6 - Συμπεράσματα και Μελλοντικές Επεκτάσεις .....	41
6.1 Σύνοψη Ευρημάτων .....	41

6.2 Οικονομική Σημασία (Managerial Implications) .....	42
6.3 Περιορισμοί της Έρευνας.....	42
6.4 Μελλοντικές Επεκτάσεις.....	42
BIBΛΙΟΓΡΑΦΙΑ.....	43

## Κατάλογος Εικόνων - Διαγραμμάτων

Εικόνα 1:Εσωτερική αρχιτεκτονική ενός κελιού LSTM. Διακρίνονται οι πύλες (Forget, Input, Output) που ελέγχουν τη ροή της πληροφορίας και τη μνήμη του δικτύου. .	27
Εικόνα 2: Συγκριτική αξιολόγηση σφάλματος πρόβλεψης μεταξύ Ελληνικών και Διεθνών δεδομένων. ....	31
Εικόνα 3: Επίδραση του χρονικού ορίζοντα μνήμης (Sequence Length) στην ακρίβεια του μοντέλου. ....	32
Εικόνα 4: Σύγκριση RMSE μεταξύ Standard LSTM και xLSTM. ....	34
Εικόνα 5: Καμπύλες εκπαίδευσης (Loss Convergence). Το xLSTM συγκλίνει ταχύτερα στο ελάχιστο σφάλμα.....	34
Εικόνα 6: Τελική πρόβλεψη τιμής Χρυσού (Standard LSTM vs xLSTM). ....	35
Εικόνα 7: Συγκριτική αξιολόγηση RMSE. Το mLSTM επιτυγχάνει την υψηλότερη ακρίβεια.....	37
Εικόνα 8: Σύγκριση Πρόβλεψης Τιμής: Το mLSTM προσαρμόζεται στη μεταβλητότητα, ενώ η Γραμμική Παλινδρόμηση αποτυγχάνει. ....	39
Εικόνα 9: Ποσοστό επιτυχίας στην πρόβλεψη της τάσης της αγοράς.....	40

## Κατάλογος Πινάκων

Πίνακας 1: Θεμελιώδεις διαφορές Machine Learning και Deep Learning .....	10
Πίνακας 2: Σύγκριση AWS vs Azure vs Google Cloud για Financial AI .....	13
Πίνακας 3: Συγκριτική ανάλυση Στατιστικής και Deep Learning.....	15
Πίνακας 4:Περιγραφική Στατιστική των Δεδομένων (2015-2024) .....	25

## Κεφάλαιο 1 – Εισαγωγή

### 1.1 Κίνητρο

Η ραγδαία εξέλιξη των ψηφιακών τεχνολογιών τα τελευταία χρόνια έχει επιφέρει σημαντικές αλλαγές σε όλους τους τομείς της οικονομίας, και ιδιαίτερα στον χρηματοοικονομικό τομέα. Οι οργανισμοί που δραστηριοποιούνται στον χώρο των χρηματοοικονομικών υπηρεσιών, όπως τράπεζες, ασφαλιστικοί φορείς και εταιρείες επενδύσεων, διαχειρίζονται καθημερινά τεράστιους όγκους δεδομένων που αφορούν συναλλαγές, επενδύσεις, προφίλ πελατών και αγορές κεφαλαίου.

Η ανάγκη για έξυπνη και αυτόματη ανάλυση αυτών των δεδομένων οδήγησε στην ενσωμάτωση τεχνολογιών Τεχνητής Νοημοσύνης (Artificial Intelligence – AI) και Προγνωστικής Ανάλυσης (Predictive Analytics), οι οποίες επιτρέπουν τη λήψη αποφάσεων βασισμένων σε δεδομένα (data-driven decision making). Παράλληλα, το Υπολογιστικό Νέφος (Cloud Computing) παρέχει την απαραίτητη υποδομή για αποθήκευση, επεξεργασία και διαχείριση δεδομένων σε μεγάλη κλίμακα, με ασφάλεια και ευελιξία.

Η συνδυασμένη χρήση των τριών αυτών τεχνολογιών – AI, Predictive Analytics και Cloud Computing – δημιουργεί ένα νέο πλαίσιο λειτουργίας για τα χρηματοοικονομικά ιδρύματα, προσφέροντας τη δυνατότητα πρόβλεψης κινδύνων, ανίχνευσης απάτης, βελτιστοποίησης επενδύσεων και αυτοματισμού λειτουργιών.

Η εργασία αυτή εστιάζει στη στρατηγική αξιοποίηση της Τεχνητής Νοημοσύνης και της Προγνωστικής Ανάλυσης σε περιβάλλοντα cloud για τη βελτίωση της αποδοτικότητας και της ασφάλειας στον χρηματοοικονομικό τομέα, συμβάλλοντας στην κατανόηση του πώς οι σύγχρονες τεχνολογίες μπορούν να μεταμορφώσουν τον τρόπο με τον οποίο λαμβάνονται επιχειρηματικές αποφάσεις.

### 1.2 Σκοπός της Εργασίας

Σκοπός της παρούσας διπλωματικής εργασίας είναι να αναδείξει τον ρόλο της Τεχνητής Νοημοσύνης και της Προγνωστικής Ανάλυσης στην ανάπτυξη, υλοποίηση και βελτιστοποίηση χρηματοοικονομικών συστημάτων που λειτουργούν σε περιβάλλοντα Cloud Computing.

Η εργασία στοχεύει να:

- Αναλύσει τις θεμελιώδεις αρχές και μεθοδολογίες της Τεχνητής Νοημοσύνης και της Μηχανικής Μάθησης (Machine Learning) όπως εφαρμόζονται στα χρηματοοικονομικά δεδομένα.
- Εξετάσει τις προκλήσεις που αντιμετωπίζει ο χρηματοοικονομικός τομέας, όπως η διαχείριση μεγάλου όγκου δεδομένων (Big Data), η προστασία προσωπικών πληροφοριών και η ανάγκη για διαφάνεια και αξιοπιστία.

- Διερευνήσει τον τρόπο με τον οποίο η υποδομή Cloud επιτρέπει την ευέλικτη και αποδοτική εφαρμογή μοντέλων AI και Predictive Analytics σε πραγματικό χρόνο.

Πέραν της θεωρητικής ανάλυσης, η εργασία περιλαμβάνει την πρακτική υλοποίηση και αξιολόγηση ενός **συστήματος πρόβλεψης χρηματοοικονομικών χρονοσειρών (Case Study)**. Συγκεκριμένα, εστιάζει στην πρόβλεψη της τιμής του χρυσού, αξιοποιώντας καινοτόμες αρχιτεκτονικές Deep Learning (xLSTM) και ελληνικά μακροοικονομικά δεδομένα, με στόχο να καταδείξει την υπεροχή των σύγχρονων μεθόδων έναντι των παραδοσιακών στατιστικών μοντέλων.

### 1.3 Ερευνητικά Ερωτήματα

Η εργασία επιδιώκει να απαντήσει στα ακόλουθα ερευνητικά ερωτήματα:

1. Ποιος είναι ο ρόλος της Τεχνητής Νοημοσύνης και της Προγνωστικής Ανάλυσης στη διαμόρφωση στρατηγικών αποφάσεων στον χρηματοοικονομικό τομέα;
2. Με ποιους τρόπους οι τεχνολογίες Cloud Computing υποστηρίζουν την αποτελεσματική εφαρμογή συστημάτων ανάλυσης δεδομένων μεγάλης κλίμακας;
3. Ποιες είναι οι κύριες προκλήσεις και τα οφέλη της ενσωμάτωσης AI και Predictive Analytics στις χρηματοοικονομικές υπηρεσίες;
4. Πώς μπορούν τα μοντέλα αυτά να συμβάλουν στη μείωση του ρίσκου, στην ανίχνευση απάτης και στη βελτίωση της αποδοτικότητας των επιχειρησιακών διαδικασιών;
5. Ποια είναι η συγκριτική απόδοση των νέων αρχιτεκτονικών xLSTM (Extended LSTM) έναντι των παραδοσιακών στατιστικών μεθόδων στην πρόβλεψη πολύπλοκων και ευμετάβλητων οικονομικών δεικτών, όπως η τιμή του χρυσού;

### 1.4 Μεθοδολογία

Η μεθοδολογία της έρευνας περιλαμβάνει:

- Ανασκόπηση βιβλιογραφίας (literature review) βασισμένη σε πρόσφατες μελέτες και επιστημονικά άρθρα σχετικά με τη χρήση AI, Cloud και Predictive Analytics στα χρηματοοικονομικά.
- Συγκριτική ανάλυση τεχνολογικών λύσεων και μεθόδων που χρησιμοποιούνται από σύγχρονους οργανισμούς.
- Εννοιολογική προσέγγιση (conceptual modeling) για την παρουσίαση ενός προτεινόμενου συστήματος ή πλαισίου λειτουργίας.

- Αξιολόγηση των δυνατοτήτων, οφελών και περιορισμών των τεχνολογιών αυτών μέσω παραδειγμάτων και υπαρχουσών εφαρμογών.

Η εργασία δεν επικεντρώνεται αποκλειστικά σε τεχνική υλοποίηση, αλλά στην ανάλυση στρατηγικής και λειτουργικής ενσωμάτωσης των τεχνολογιών αυτών σε πραγματικά επιχειρηματικά περιβάλλοντα.

## 1.5 Δομή της Εργασίας

Η εργασία οργανώνεται στα εξής κεφάλαια:

- **Κεφάλαιο 1: Εισαγωγή** – Παρουσιάζεται το κίνητρο, ο σκοπός, τα ερευνητικά ερωτήματα και η μεθοδολογία της μελέτης.
- **Κεφάλαιο 2: Μηχανική Μάθηση και Analytics** – Αναλύονται οι βασικές έννοιες της Τεχνητής Νοημοσύνης, της Μηχανικής Μάθησης και της Προγνωστικής Ανάλυσης.
- **Κεφάλαιο 3: Προκλήσεις στον Χρηματοοικονομικό Τομέα** – Περιγράφονται τα προβλήματα, οι ευκαιρίες και οι τεχνολογικές προοπτικές του κλάδου.
- **Κεφάλαιο 4: Προτεινόμενο Σύστημα** – Παρουσιάζεται ένα υποδειγματικό πλαίσιο ενσωμάτωσης AI και Predictive Analytics σε Cloud περιβάλλον.
- **Κεφάλαιο 5: Πειραματική Αποτίμηση** – Παρουσιάζονται τα αποτελέσματα αξιολόγησης και οι επιδόσεις του προτεινόμενου πλαισίου.
- **Κεφάλαιο 6: Συμπεράσματα και Μελλοντικές Προεκτάσεις** – Συνοψίζονται τα ευρήματα και προτείνονται μελλοντικές κατευθύνσεις έρευνας.

## 1.6 Αναμενόμενη Συνεισφορά

Η εργασία φιλοδοξεί να συμβάλει:

- Στην κατανόηση της σχέσης μεταξύ AI, Predictive Analytics και Cloud Computing στον χρηματοοικονομικό τομέα.
- Στην ανάδειξη στρατηγικών οφελών από την υιοθέτηση αυτών των τεχνολογιών, όπως η βελτίωση της αποτελεσματικότητας, της διαφάνειας και της ασφάλειας.
- Στην παροχή ενός θεωρητικού πλαισίου για την αξιολόγηση της τεχνολογικής ωριμότητας και των προκλήσεων ενσωμάτωσης αυτών των συστημάτων.

## Κεφάλαιο 2 – Μηχανική Μάθηση και Analytics

### 2.1 Εισαγωγή

Η **Μηχανική Μάθηση (Machine Learning – ML)** αποτελεί θεμελιώδη υποκλάδο της Τεχνητής Νοημοσύνης (Artificial Intelligence – AI) και έχει εξελιχθεί σε ένα από τα σημαντικότερα εργαλεία για την ανάλυση και αξιοποίηση δεδομένων. Στόχος της είναι η ανάπτυξη μοντέλων και αλγορίθμων που επιτρέπουν στους υπολογιστές να μαθαίνουν από τα δεδομένα, να αναγνωρίζουν πρότυπα και να λαμβάνουν αποφάσεις χωρίς ρητό προγραμματισμό (Lăzăroiu et al., 2023).

Η εφαρμογή της Μηχανικής Μάθησης σε συνδυασμό με την **Προγνωστική Ανάλυση (Predictive Analytics)** έχει επιτρέψει στους οργανισμούς να μετατρέπουν τον τεράστιο όγκο δεδομένων τους σε γνώση με επιχειρησιακή αξία. Στο πλαίσιο των **Cloud-Based Financial Systems**, αυτές οι τεχνολογίες συμβάλλουν στη λήψη αποφάσεων βασισμένων σε δεδομένα, στην πρόβλεψη κινδύνων και στην αυτοματοποίηση κρίσιμων διαδικασιών (Samuel, 2023).

### 2.2 Θεμελιώδεις Έννοιες της Μηχανικής Μάθησης

Η Μηχανική Μάθηση μπορεί να ταξινομηθεί σε τρεις κύριες κατηγορίες, ανάλογα με τη φύση των δεδομένων και το ζητούμενο πρόβλημα (Rehan, 2022):

#### 1. Εποπτευόμενη Μάθηση (Supervised Learning):

Χρησιμοποιεί δεδομένα που περιλαμβάνουν εισόδους και γνωστές εξόδους (labels). Στόχος είναι η εκπαίδευση ενός μοντέλου που μπορεί να προβλέψει την έξοδο για νέα, άγνωστα δεδομένα.

- **Παραδείγματα αλγορίθμων:** Linear Regression, Logistic Regression, Decision Trees, Random Forests, Support Vector Machines (SVM).
- **Εφαρμογές:** Πρόβλεψη πιστωτικού κινδύνου, ταξινόμηση συναλλαγών σε “fraud” ή “non-fraud”, πρόβλεψη τιμών μετοχών.

#### 2. Μη Εποπτευόμενη Μάθηση (Unsupervised Learning):

Στόχος είναι η ανίχνευση προτύπων ή ομάδων μέσα στα δεδομένα χωρίς προκαθορισμένες κατηγορίες.

- **Παραδείγματα αλγορίθμων:** K-Means Clustering, Hierarchical Clustering, Principal Component Analysis (PCA).
- **Εφαρμογές:** Ομαδοποίηση πελατών (customer segmentation), ανάλυση αγοραστικής συμπεριφοράς, ανίχνευση ανωμαλιών (anomaly detection).

### 3. Ημι-Εποπτευόμενη και Ενισχυτική Μάθηση (Semi-supervised & Reinforcement Learning):

- **Semi-supervised learning** χρησιμοποιείται όταν υπάρχει περιορισμένος αριθμός επισημασμένων δεδομένων, ενώ η **Reinforcement Learning** βασίζεται στην εκμάθηση μέσω επιβράβευσης, όπως στα trading bots και στα συστήματα αυτόματης επένδυσης (Pamisetty, 2022).

Η Μηχανική Μάθηση αξιοποιεί στατιστικές μεθόδους, εξόρυξη δεδομένων (data Mining) και βελτιστοποίηση (optimization), με σκοπό τη δημιουργία μοντέλων που μπορούν να εντοπίζουν συσχετισμούς, να ανακαλύπτουν τάσεις και να προβλέπουν μελλοντικά γεγονότα με ακρίβεια.

#### 2.2.1 Η Επιλογή Μεταξύ Machine Learning και Deep Learning

Ένα κρίσιμο ερώτημα κατά τον σχεδιασμό του συστήματος ήταν η επιλογή μεταξύ παραδοσιακών αλγορίθμων Μηχανικής Μάθησης και Βαθιάς Μάθησης (Deep Learning). Η επιλογή εξαρτάται από τον όγκο των δεδομένων και την πολυπλοκότητα του προβλήματος.

Πίνακας 1: Θεμελιώδεις διαφορές Machine Learning και Deep Learning

Παράγοντας	Παραδοσιακή Μηχανική Μάθηση (ML)	Βαθιά Μάθηση (Deep Learning - DL)
Αλγόριθμοι	Linear Regression, SVM, Decision Trees, Random Forest.	CNN, RNN, LSTM, xLSTM, Transformers.
Απαίτηση Δεδομένων	Αποδίδει καλά με μικρούς έως μεσαίους όγκους δεδομένων.	Η απόδοση βελτιώνεται εκθετικά με μεγάλους όγκους δεδομένων (Big Data).
Εξοπλισμός (Hardware)	Λειτουργεί αποδοτικά σε τυπικούς επεξεργαστές (CPU).	Απαιτεί ισχυρές κάρτες γραφικών (GPU) ή TPU για παράλληλη επεξεργασία.

Παράγοντας	Παραδοσιακή Μηχανική Μάθηση (ML)	Βαθιά Μάθηση (Deep Learning - DL)
Εξαγωγή Χαρακτηριστικών	Χειροκίνητη (Manual Feature Engineering). Ο ειδικός επιλέγει τι είναι σημαντικό.	Αυτόματη. Το δίκτυο μαθαίνει μόνο του τα χαρακτηριστικά από τα δεδομένα.
Χρόνος Εκπαίδευσης	Σύντομος (λεπτά ή ώρες).	Μακρύς (ώρες, μέρες ή εβδομάδες).
Ερμηνευσιμότητα	Υψηλή. Είναι εύκολο να καταλάβουμε γιατί πάρθηκε μια απόφαση.	Χαμηλή ("Black Box"). Δύσκολη η ερμηνεία των εσωτερικών βαρών.

Στην περίπτωση της πρόβλεψης της τιμής του χρυσού, η πολυπλοκότητα των χρονοσειρών και η ανάγκη για εντοπισμό μη-γραμμικών μοτίβων (non-linear patterns) καθιστούν το **Deep Learning** και συγκεκριμένα τα δίκτυα **xLSTM** την βέλτιστη επιλογή, παρά τις αυξημένες απαιτήσεις σε υπολογιστικούς πόρους.

### 2.3 Προγνωστική Ανάλυση (Predictive Analytics)

Η **Predictive Analytics** αποτελεί ένα σύνολο τεχνικών και μεθόδων που χρησιμοποιούνται για την πρόβλεψη μελλοντικών συμπεριφορών, αποτελεσμάτων ή κινδύνων, βασισμένων σε ιστορικά δεδομένα. Οι πιο διαδεδομένες τεχνικές περιλαμβάνουν:

- **Regression Analysis:** Χρησιμοποιείται για την πρόβλεψη συνεχών μεταβλητών (π.χ. πρόβλεψη επιτοκίων ή πιστωτικού ρίσκου).
- **Classification Models:** Χρησιμοποιούνται για την κατηγοριοποίηση γεγονότων σε διακριτές ομάδες (π.χ. fraud ή non-fraud).
- **Time Series Forecasting:** Προβλέπει μεταβολές τιμών ή τάσεις με βάση την ιστορική ακολουθία δεδομένων (π.χ. πρόβλεψη αγοράς μετοχών).
- **Anomaly Detection:** Εντοπίζει ασυνήθιστες ή ύποπτες συμπεριφορές στις συναλλαγές, σημαντικό στοιχείο για fraud detection. (Akinniyi, 2023)

Η προγνωστική ανάλυση προσφέρει στα χρηματοοικονομικά ιδρύματα τη δυνατότητα να προβλέπουν μελλοντικούς κινδύνους και να λαμβάνουν προληπτικές αποφάσεις αντί να αντιδρούν εκ των υστέρων (Lăzăroiu et al., 2023).

## 2.4 Ενσωμάτωση AI και Cloud Computing στα Predictive Analytics

Το Cloud Computing αποτελεί τον καταλύτη για την εφαρμογή μοντέλων Μηχανικής Μάθησης μεγάλης κλίμακας. Οι υπηρεσίες cloud, όπως οι Amazon Web Services (AWS), Microsoft Azure και Google Cloud Platform (GCP), παρέχουν εργαλεία ανάλυσης δεδομένων, μηχανικής μάθησης και αποθήκευσης, προσφέροντας:

- **Υπολογιστική ισχύ και ευελιξία (scalability)** για την εκπαίδευση πολύπλοκων μοντέλων.
- **Real-time data processing** για ανίχνευση απάτης ή ανάλυση συναλλαγών σε πραγματικό χρόνο.
- **Ασφάλεια δεδομένων και κανονιστική συμμόρφωση (compliance)**, κρίσιμη για τα χρηματοοικονομικά ιδρύματα (Samuel, 2023).

Σύμφωνα με τον Rehan (2021), ο συνδυασμός AI και Cloud επιτρέπει τη δημιουργία συστημάτων real-time fraud detection με χρήση deep learning αρχιτεκτονικών, όπως Convolutional Neural Networks (CNN) και Recurrent Neural Networks (RNN). Αυτά τα συστήματα μαθαίνουν από εκατομμύρια συναλλαγές, εντοπίζοντας μοτίβα που διαφεύγουν της ανθρώπινης παρατήρησης.

Η ενσωμάτωση της AI στο Cloud περιλαμβάνει επίσης τη χρήση API services, όπως AWS SageMaker ή Google AutoML, που καθιστούν τη διαδικασία ανάλυσης δεδομένων πιο αυτοματοποιημένη και προσβάσιμη.

### 2.4.1 Συγκριτική Ανάλυση Παρόχων Υπολογιστικού Νέφους

Η επιλογή του κατάλληλου παρόχου Cloud είναι κρίσιμη για την ανάπτυξη χρηματοοικονομικών συστημάτων AI. Στον Πίνακα που ακολουθεί, συγκρίνονται οι τρεις κυρίαρχοι πάροχοι (Amazon Web Services, Microsoft Azure, Google Cloud Platform) ως προς τις δυνατότητές τους στην Τεχνητή Νοημοσύνη και τη διαχείριση μεγάλου όγκου δεδομένων.

Πίνακας 2: Σύγκριση AWS vs Azure vs Google Cloud για Financial AI

Χαρακτηριστικό	Amazon Web Services (AWS)	Microsoft Azure	Google Cloud Platform (GCP)
Κυρίαρχη Υπηρεσία AI	Amazon SageMaker	Azure Machine Learning	Vertex AI (TensorFlow)
Πλεονέκτημα	Ωριμότητα, μεγαλύτερο μερίδιο αγοράς, πληθώρα εργαλείων.	Ισχυρή ενσωμάτωση με εταιρικά περιβάλλοντα (Windows/Office).	Κορυφαία τεχνολογία σε Big Data Analytics & Open Source (Kubernetes).
Υπολογιστικό Κόστος	Ευέλικτο (Pay-as-you-go), αλλά συχνά υψηλό για πολύπλοκα μοντέλα.	Ανταγωνιστικό για κατόχους Enterprise Agreements.	Συνήθως οικονομικότερο για Deep Learning (TPUs) και Containerization.
Data Analytics	AWS Redshift	Azure Synapse Analytics	Google BigQuery (Serverless)
Καταλληλότητα για Finance	Υψηλή (χρησιμοποιείται από NASDAQ, Capital One).	Υψηλή (χρησιμοποιείται από πολλές τράπεζες λόγω ασφάλειας).	Υψηλή (ιδανικό για High Frequency Trading & Analytics).

Από την ανάλυση προκύπτει ότι και οι τρεις πλατφόρμες προσφέρουν ισχυρά εργαλεία. Ωστόσο, για την παρούσα εργασία που εστιάζει σε Deep Learning (xLSTM/PyTorch), το περιβάλλον του **Google Colab (μέρος του οικοσυστήματος της Google)** προσέφερε την απαραίτητη πρόσβαση σε GPU (Graphics Processing Units) χωρίς κόστος, διευκολύνοντας την πειραματική διαδικασία.

## 2.5 Μεθοδολογίες Εξαγωγής Analytics

Η διαδικασία παραγωγής analytics περιλαμβάνει διαδοχικά στάδια (Akinniyi, 2023):

### 1. Συλλογή Δεδομένων (Data Collection):

Τα δεδομένα αντλούνται από διάφορες πηγές – συναλλαγές, πελατειακές βάσεις, επενδυτικά χαρτοφυλάκια, online συστήματα πληρωμών.

### 2. Καθαρισμός και Προεπεξεργασία (Data Preprocessing):

Περιλαμβάνει τη διαχείριση ελλιπών ή θορυβωδών δεδομένων, την κανονικοποίηση (normalization) και τη μείωση διαστάσεων (dimensionality reduction).

### 3. Ανάπτυξη Μοντέλου (Model Development):

Επιλογή και εκπαίδευση κατάλληλου μοντέλου μηχανικής μάθησης.

### 4. Αξιολόγηση (Evaluation):

Χρήση μετρικών απόδοσης, όπως **Accuracy, Precision, Recall, F1-score, ROC-AUC**, για την εκτίμηση της αποτελεσματικότητας του μοντέλου.

### 5. Οπτικοποίηση και Ερμηνεία (Visualization and Interpretation):

Παρουσίαση των αποτελεσμάτων με εργαλεία όπως Power BI, Tableau ή Python libraries (Matplotlib, Seaborn), διευκολύνοντας τη λήψη αποφάσεων.

Η διαδικασία αυτή επιτρέπει την **εξαγωγή γνώσης (Knowledge Extraction)** και τη **μετατροπή δεδομένων σε στρατηγική πληροφόρηση (Business Intelligence)**.

## 2.6 Ο Ρόλος της Τεχνητής Νοημοσύνης στα Financial Analytics

Η Τεχνητή Νοημοσύνη μεταμορφώνει τη φύση των **Financial Analytics**, επιτρέποντας:

- **Αυτοματοποιημένες αποφάσεις** (automated decision-making) σε δευτερόλεπτα.
- **Προσωποποιημένες υπηρεσίες** (personalized financial recommendations).
- **Δυναμική αξιολόγηση κινδύνου** σε πραγματικό χρόνο.

Όπως αναφέρει ο Pamisetty (2022), τα **AI-powered analytics systems** βελτιώνουν την αποδοτικότητα και μειώνουν το ανθρώπινο σφάλμα, ενώ ταυτόχρονα συμβάλλουν στη δημιουργία **βιώσιμων και διαφανών οικοσυστημάτων**.

Η **Predictive Intelligence** έχει πλέον καθιερωθεί ως κρίσιμο εργαλείο στρατηγικής, επιτρέποντας στις επιχειρήσεις να προνοούν αντί να αντιδρούν.

## 2.7 Σύγκριση Παραδοσιακών Μεθόδων και Deep Learning

Για την κατανόηση της αναγκαιότητας μετάβασης σε πολύπλοκες αρχιτεκτονικές, είναι απαραίτητη η σύγκριση των χαρακτηριστικών των παραδοσιακών στατιστικών μεθόδων έναντι των Νευρωνικών Δικτύων όπου καταλήγουμε στο ότι η επιλογή της μεθόδου εξαρτάται από τη φύση του προβλήματος.

Πίνακας 3: Συγκριτική ανάλυση Στατιστικής και Deep Learning

Χαρακτηριστικό	Στατιστικές Μέθοδοι (π.χ. Linear Regression)	Deep Learning (π.χ. LSTM/χLSTM)
Πολυπλοκότητα Σχέσεων	Γραμμικές σχέσεις, απλή δομή.	Μη-γραμμικές, πολύπλοκες σχέσεις.
Απαίτηση Δεδομένων	Αποδίδουν καλά και με μικρά datasets.	Απαιτούν μεγάλο όγκο δεδομένων για εκπαίδευση.
Εξαγωγή Χαρακτηριστικών	Χειροκίνητη (Manual Feature Engineering).	Αυτόματη (Automatic Feature Extraction).
Ερμηνευσιμότητα	Υψηλή. Ξέρουμε ακριβώς πώς βγαίνει το αποτέλεσμα.	Χαμηλή. Δύσκολη η ερμηνεία των βαρών.
Υπολογιστικό Κόστος	Χαμηλό, τρέχει σε απλούς CPU.	Υψηλό, απαιτεί χρήση GPU/TPU.
Διαχείριση Χρονοσειρών	Περιορισμένη μνήμη (π.χ. ARIMA).	Μακροχρόνια Μνήμη (Long-Term Dependencies).

## 2.8 Συμπεράσματα

Η Μηχανική Μάθηση και η Προγνωστική Ανάλυση αποτελούν δύο από τους σημαντικότερους πυλώνες της σύγχρονης χρηματοοικονομικής τεχνολογίας. Η σύζευξή τους με τις δυνατότητες του Cloud Computing επιτρέπει την ανάπτυξη και λειτουργία συστημάτων μεγάλης κλίμακας που προσφέρουν ακρίβεια, ταχύτητα και προσαρμοστικότητα.

Η κατανόηση των αρχών της AI, των τεχνικών ML και των διαδικασιών παραγωγής analytics είναι απαραίτητη για κάθε οργανισμό που επιθυμεί να εκμεταλλευτεί τα δεδομένα του για στρατηγική ανάπτυξη και καινοτομία.

## Κεφάλαιο 3 – Προκλήσεις στον Χρηματοοικονομικό Τομέα

### 3.1 Εισαγωγή

Ο χρηματοοικονομικός τομέας βρίσκεται σήμερα στο επίκεντρο μιας **τεχνολογικής επανάστασης**, που καθοδηγείται από την ενσωμάτωση της **Τεχνητής Νοημοσύνης (Artificial Intelligence – AI)**, της **Προγνωστικής Ανάλυσης (Predictive Analytics)** και των **Cloud-Based υποδομών**.

Παρότι οι τεχνολογίες αυτές υπόσχονται βελτίωση της αποδοτικότητας, μείωση κόστους και ταχύτερη λήψη αποφάσεων, η εφαρμογή τους δεν είναι χωρίς προκλήσεις.

Οι χρηματοπιστωτικοί οργανισμοί καλούνται να αντιμετωπίσουν ζητήματα που σχετίζονται με:

- τη διαχείριση και ασφάλεια μεγάλου όγκου δεδομένων,
- την ερμηνευσιμότητα των μοντέλων AI,
- την κανονιστική συμμόρφωση (compliance),
- την προστασία της ιδιωτικότητας,
- και την τεχνολογική πολυπλοκότητα των cloud συστημάτων (Lăzăroiu et al., 2023).

Η κατανόηση αυτών των προκλήσεων είναι καθοριστική για την επιτυχή ενσωμάτωση των έξυπνων τεχνολογιών στα σύγχρονα οικονομικά οικοσυστήματα.

### 3.2 Διαχείριση και Ποιότητα Δεδομένων

Η βάση κάθε συστήματος Predictive Analytics είναι η **ποιότητα των δεδομένων**. Τα χρηματοοικονομικά ιδρύματα επεξεργάζονται τεράστιους όγκους πληροφοριών που προέρχονται από ποικίλες πηγές — τραπεζικές συναλλαγές, επενδύσεις, ψηφιακές πληρωμές, αγορές κεφαλαίου, και πλατφόρμες πελατών.

Σύμφωνα με τον Samuel (2023), η **ακρίβεια, πληρότητα και συνέπεια** των δεδομένων επηρεάζει άμεσα την αποτελεσματικότητα των μοντέλων μηχανικής μάθησης. Ελλιπή ή λανθασμένα δεδομένα μπορούν να οδηγήσουν σε **bias**, μειωμένη αξιοπιστία και λάθος αποφάσεις.

Η **διαχείριση δεδομένων (Data Governance)** αποτελεί κρίσιμο στοιχείο για κάθε οργανισμό. Περιλαμβάνει πολιτικές και διαδικασίες που εξασφαλίζουν τη σωστή συλλογή, αποθήκευση, πρόσβαση και χρήση των δεδομένων σε όλο τον κύκλο ζωής τους.

Επιπλέον, η υιοθέτηση **Cloud υποδομών** (AWS, Azure, GCP) δημιουργεί νέες ευκαιρίες αλλά και κινδύνους. Αν και το cloud προσφέρει ευελιξία και επεκτασιμότητα (scalability), αυξάνει ταυτόχρονα τις απαιτήσεις σε **ασφάλεια, έλεγχο πρόσβασης και συμμόρφωση** (Pamisetty, 2022).

### 3.3 Ιδιωτικότητα, Ασφάλεια και Κανονιστική Συμμόρφωση

Η **προστασία της ιδιωτικότητας και των οικονομικών δεδομένων** αποτελεί κορυφαία προτεραιότητα για τον χρηματοοικονομικό τομέα.

Η ανάλυση μεγάλων δεδομένων (Big Data Analytics) και η χρήση AI συχνά απαιτούν την πρόσβαση σε ευαίσθητες πληροφορίες, όπως οικονομικά προφίλ, καταναλωτικές συνήθειες και ιστορικά συναλλαγών.

Η **ευρωπαϊκή νομοθεσία για την προστασία προσωπικών δεδομένων (GDPR)** και τα διεθνή πρότυπα **ISO/IEC 27001** καθορίζουν αυστηρούς κανόνες σχετικά με την αποθήκευση και επεξεργασία δεδομένων.

Σύμφωνα με τον Akinniyi (2023), η υλοποίηση τεχνικών **data encryption, access control** και **anonymization** είναι απαραίτητη για την προστασία από κυβερνοεπιθέσεις και διαρροές πληροφοριών.

Η αυξανόμενη εξάρτηση από **cloud-based υπηρεσίες** καθιστά κρίσιμη τη διασφάλιση ότι οι πάροχοι cloud πληρούν υψηλά πρότυπα ασφάλειας και συμμόρφωσης.

Πέρα από την ασφάλεια, οι οργανισμοί πρέπει να εξασφαλίσουν και τη **διαφάνεια των μοντέλων AI**. Ο Ευρωπαϊκός Κανονισμός AI Act (2024) εισάγει την υποχρέωση ερμηνευσιμότητας και τεκμηρίωσης των αυτόματων αποφάσεων, ώστε να διασφαλιστεί η υπευθυνότητα (accountability) των συστημάτων.

### 3.4 Ανίχνευση Απάτης (Fraud Detection) και Διαχείριση Κινδύνου

Η **οικονομική απάτη (financial fraud)** αποτελεί μία από τις σημαντικότερες προκλήσεις στον τραπεζικό και ασφαλιστικό κλάδο.

Η ανίχνευση ύποπτων συναλλαγών σε πραγματικό χρόνο απαιτεί την επεξεργασία τεράστιου όγκου δεδομένων με ακρίβεια και ταχύτητα.

Η Τεχνητή Νοημοσύνη, και ειδικότερα τα **μοντέλα Μηχανικής Μάθησης**, έχουν καταστήσει δυνατή την ανίχνευση απάτης μέσω της αναγνώρισης μοτίβων που διαφεύγουν του ανθρώπινου ελέγχου.

Όπως αναφέρει ο Rehan (2021), η χρήση **Deep Learning τεχνικών** όπως **Convolutional Neural Networks (CNN)** και **Recurrent Neural Networks (RNN)** επιτρέπει την αναγνώριση μη γραμμικών συσχετίσεων μεταξύ χαρακτηριστικών συναλλαγών.

Επιπλέον, η **Προγνωστική Ανάλυση** συμβάλλει στην **εκτίμηση πιστωτικού κινδύνου (credit risk assessment)**, προβλέποντας τη συμπεριφορά πελατών βάσει ιστορικών δεδομένων (Lăzăroiu et al., 2023).

Η λήψη αποφάσεων βασισμένων σε αυτά τα μοντέλα επιτρέπει:

- την **πρόληψη** ύποπτων ενεργειών πριν ολοκληρωθούν,
- τη **μείωση** των ψευδών θετικών (false positives),
- και τη **βελτίωση** της εμπειρίας πελάτη, καθώς μειώνονται οι άσκοπες παρεμβάσεις.

Ωστόσο, η αποτελεσματικότητα των συστημάτων αυτών εξαρτάται σε μεγάλο βαθμό από την ποιότητα των δεδομένων και την κατάλληλη **ρύθμιση παραμέτρων (model tuning)**.

### 3.5 Ερμηνευσιμότητα και Διαφάνεια των Μοντέλων (Explainable AI)

Ένα από τα πλέον συζητημένα ζητήματα στην Τεχνητή Νοημοσύνη είναι η **ερμηνευσιμότητα των μοντέλων (Explainability)**. Τα σύγχρονα συστήματα βασισμένα σε **Deep Learning** είναι εξαιρετικά ισχυρά, αλλά συχνά λειτουργούν ως **“black boxes”**, χωρίς σαφή εξήγηση του πώς καταλήγουν σε ένα αποτέλεσμα.

Η έλλειψη ερμηνευσιμότητας είναι ιδιαίτερα κρίσιμη στα χρηματοοικονομικά, όπου κάθε απόφαση (π.χ. έγκριση δανείου ή επισήμανση απάτης) πρέπει να τεκμηριώνεται (Akinpiniyi, 2023). Οι οργανισμοί στρέφονται σε λύσεις **Explainable AI (XAI)**, που επιτρέπουν την οπτικοποίηση των σημαντικότερων μεταβλητών και την κατανόηση της διαδικασίας λήψης απόφασης.

Τεχνικές όπως:

- **LIME (Local Interpretable Model-Agnostic Explanations)**,
- **SHAP (Shapley Additive Explanations)**,

παρέχουν τη δυνατότητα να κατανοηθεί ποιοι παράγοντες επηρεάζουν περισσότερο μια πρόβλεψη (Samuel, 2023).

Η διαφάνεια των μοντέλων ενισχύει τη **σχέση εμπιστοσύνης** μεταξύ οργανισμών και πελατών, καθώς και τη **συμμόρφωση** με τις κανονιστικές απαιτήσεις.

## 3.6 Χρησιμοποιούμενοι Αλγόριθμοι και Τεχνικές στον Χρηματοοικονομικό Τομέα

Η αξιοποίηση αλγορίθμων Μηχανικής Μάθησης (Machine Learning) και Τεχνητής Νοημοσύνης (AI) έχει οδηγήσει σε σημαντικές εξελίξεις στη χρηματοοικονομική ανάλυση, την ανίχνευση απάτης και τη διαχείριση κινδύνου.

Οι πιο διαδεδομένες τεχνικές που εφαρμόζονται σήμερα στα Cloud-Based Financial Systems περιλαμβάνουν:

### ◆ Supervised Learning Algorithms

#### 1. Logistic Regression

- Χρησιμοποιείται ευρέως στην πρόβλεψη πιστωτικού κινδύνου (credit risk scoring) και στη διάκριση ύποπτων συναλλαγών.
- Παράγει ερμηνεύσιμα αποτελέσματα, κάτι που διευκολύνει τη συμμόρφωση με κανονισμούς όπως το GDPR και το AI Act. (Pamisetty, 2022; Lăzăroiu et al., 2023)

#### 2. Decision Trees & Random Forests

- Προσφέρουν υψηλή ακρίβεια και δυνατότητα εξήγησης των αποφάσεων.
- Εφαρμόζονται στην ανάλυση επενδυτικών ρίσκων και στην πρόβλεψη αγοραστικών τάσεων.
- Οι Random Forests μειώνουν τον κίνδυνο υπερπροσαρμογής (overfitting) και είναι κατάλληλες για πολύπλοκα datasets. (Samuel, 2023)

#### 3. Support Vector Machines (SVMs)

- Ιδανικές για δυαδική ταξινόμηση (fraud/no fraud).
- Εμφανίζουν καλή απόδοση σε περιπτώσεις όπου τα δεδομένα δεν είναι γραμμικά διαχωρίσιμα. (Akinniyi, 2023)

## ◆ Unsupervised Learning & Clustering

### 1. K-Means Clustering

- Εντοπίζει ομάδες πελατών με παρόμοια οικονομική συμπεριφορά (customer segmentation).
- Συχνά εφαρμόζεται σε marketing analytics και προσωποποιημένες προτάσεις επενδύσεων. (Pamisetty, 2022)

### 2. Anomaly Detection Models (Isolation Forest, DBSCAN)

- Ειδικά σχεδιασμένοι για την ανίχνευση ασυνήθιστων συναλλαγών που μπορεί να υποδηλώνουν απάτη.
- Τα Cloud συστήματα επιτρέπουν real-time ανάλυση τέτοιων ανωμαλιών. (Rehan, 2021)

## ◆ Deep Learning Models

### 1. Recurrent Neural Networks (RNN) & LSTM Networks

- Χρησιμοποιούνται για πρόβλεψη τιμών μετοχών, επιτοκίων ή συναλλαγματικών ισοτιμιών.
- Μπορούν να μάθουν μοτίβα σε χρονοσειρές δεδομένων (time series prediction). (Samuel, 2023; Lăzăroiu et al., 2023)

### 2. Convolutional Neural Networks (CNN)

- Εφαρμόζονται σε fraud detection με ανάλυση “εικόνων” συναλλαγών ή μοτίβων χρηματικών ροών. (Akinniyi, 2023)

### 3. Autoencoders & Deep Belief Networks

- Χρησιμοποιούνται για feature extraction και dimensionality reduction πριν από την πρόβλεψη.
- Ιδιαίτερα χρήσιμοι σε high-dimensional datasets που προκύπτουν από cloud συστήματα. (Rehan, 2021)

## ◆ Hybrid & Cloud-Native Approaches

Τα τελευταία χρόνια, έχει αυξηθεί η χρήση υβριδικών μοντέλων, όπου συνδυάζονται αλγόριθμοι AI με cloud-native pipelines (π.χ. AWS SageMaker, Azure Machine Learning, Google Vertex AI).

- Αυτά τα περιβάλλοντα επιτρέπουν:
  - αυτοματοποιημένο training μοντέλων,
  - real-time deployment,
  - παρακολούθηση απόδοσης (model monitoring),
  - και επαναπροσαρμογή (model retraining).

Η προσέγγιση αυτή έχει υιοθετηθεί από μεγάλες fintech εταιρείες (PayPal, Revolut, Stripe) και χρηματοπιστωτικά ιδρύματα για εντοπισμό απάτης, πρόβλεψη κινδύνου και ανάλυση συμπεριφοράς πελατών.

### 3.7 Προκλήσεις στην Πρόβλεψη Χρονοσειρών (Time Series Forecasting)

Πέρα από την ανίχνευση απάτης, μια από τις μεγαλύτερες προκλήσεις για τα σύγχρονα χρηματοοικονομικά συστήματα είναι η ακριβής πρόβλεψη χρονοσειρών (Time Series Forecasting). Οι χρηματοοικονομικές αγορές χαρακτηρίζονται από:

- **Έντονη Μεταβλητότητα (Volatility):** Οι τιμές επηρεάζονται από απρόβλεπτα γεγονότα, δημιουργώντας 'θόρυβο' στα δεδομένα.
- **Μη-Γραμμικότητα (Non-linearity):** Οι σχέσεις μεταξύ μακροοικονομικών δεικτών (π.χ. πληθωρισμός, επιτόκια) και τιμών (π.χ. χρυσός) δεν είναι γραμμικές, καθιστώντας τα απλά στατιστικά μοντέλα ανεπαρκή.
- **Μακροχρόνιες Εξαρτήσεις (Long-term Dependencies):** Γεγονότα που συνέβησαν μήνες ή χρόνια πριν μπορεί να επηρεάζουν τη σημερινή τιμή.

Αυτές οι προκλήσεις καθιστούν απαραίτητη τη χρήση προηγμένων αρχιτεκτονικών Deep Learning, όπως τα **Long Short-Term Memory (LSTM)** και οι παραλλαγές τους (xLSTM), που είναι ειδικά σχεδιασμένα να 'θυμούνται' πληροφορίες για μεγάλα χρονικά διαστήματα και να φιλτράρουν τον θόρυβο, όπως θα αναλυθεί στο πρακτικό μέρος της εργασίας.

### 3.8 Τεχνολογικές Τάσεις και Μελλοντικές Κατευθύνσεις

Η ενσωμάτωση της Τεχνητής Νοημοσύνης και των Analytics στον χρηματοοικονομικό τομέα δεν είναι στατική, εξελίσσεται διαρκώς.

Σύμφωνα με τον Ramisetty (2022), οι σημαντικότερες τάσεις που διαμορφώνουν το μέλλον του κλάδου περιλαμβάνουν:

- **Αυξημένη χρήση Cloud-Based AI υπηρεσιών**, που επιτρέπουν real-time analytics και scalability.
- **Ενσωμάτωση Blockchain τεχνολογιών** για ασφάλεια, διαφάνεια και ανιχνευσιμότητα συναλλαγών (Lăzăroiu et al., 2023).
- **Ανάδυση των Quantum Machine Learning συστημάτων**, που υπόσχονται ταχύτερη επεξεργασία δεδομένων μεγάλης κλίμακας.
- **Συνδυασμός Predictive και Prescriptive Analytics**, με στόχο όχι μόνο την πρόβλεψη αλλά και τη βελτιστοποίηση ενεργειών (Samuel, 2023).
- **Περισσότερη ρύθμιση και ηθική εποπτεία** της χρήσης AI μέσω διεθνών οργανισμών (OECD, EU AI Act, ISO).

Η συνεχής εξέλιξη αυτών των τεχνολογιών καθιστά αναγκαία την προσαρμοστικότητα των επιχειρήσεων, αλλά και την εκπαίδευση του ανθρώπινου δυναμικού για την αξιοποίηση των νέων δυνατοτήτων.

### 3.9 Συμπεράσματα

Ο χρηματοοικονομικός τομέας αντιμετωπίζει ένα πολύπλοκο σύνολο προκλήσεων που σχετίζονται με τη χρήση της Τεχνητής Νοημοσύνης και της Προγνωστικής Ανάλυσης.

Η επιτυχής αξιοποίηση αυτών των τεχνολογιών εξαρτάται από:

- την ορθή διαχείριση και ασφάλεια των δεδομένων,
- τη διαφάνεια και ερμηνευσιμότητα των αλγορίθμων,
- και τη στρατηγική ενσωμάτωσή τους σε cloud περιβάλλοντα.

Η αντιμετώπιση των προκλήσεων αυτών θα επιτρέψει στα χρηματοοικονομικά ιδρύματα να μεταβούν σε ένα πιο ευφύες, ασφαλές και βιώσιμο μοντέλο λειτουργίας, ενισχύοντας τη λήψη αποφάσεων και την εμπιστοσύνη των πελατών.

## Κεφάλαιο 4: Σχεδιασμός και Υλοποίηση Συστήματος Πρόβλεψης

### 4.1 Επισκόπηση Αρχιτεκτονικής (System Overview)

Στο παρόν κεφάλαιο παρουσιάζεται η μεθοδολογία ανάπτυξης και η αρχιτεκτονική του προτεινόμενου συστήματος πρόβλεψης της τιμής του χρυσού. Το σύστημα αναπτύχθηκε στη γλώσσα προγραμματισμού **Python**, αξιοποιώντας τη βιβλιοθήκη **PyTorch** για την υλοποίηση των Νευρωνικών Δικτύων.

Η ροή εργασίας (pipeline) του συστήματος αποτελείται από τρία διακριτά στάδια:

1. **Μηχανική Δεδομένων (Data Engineering):** Συλλογή, καθαρισμός και μετασχηματισμός των δεδομένων.
2. **Αρχιτεκτονική Μοντέλων (Model Architecture):** Σχεδιασμός των αλγορίθμων Standard LSTM, sLSTM και mLSTM.
3. **Διαδικασία Εκπαίδευσης (Training Process):** Παραμετροποίηση και βελτιστοποίηση των μοντέλων.

### 4.2 Συλλογή και Προεπεξεργασία Δεδομένων

Η ποιότητα των δεδομένων αποτελεί τον κρίσιμότερο παράγοντα για την απόδοση του συστήματος. Χρησιμοποιήθηκαν δύο κύριες πηγές δεδομένων:

1. **Μακροοικονομικά Δεδομένα (Τράπεζα της Ελλάδος):**
  - *Επιτόκιο Νέων Καταθέσεων:* Μηνιαίος δείκτης που αντικατοπτρίζει τη νομισματική πολιτική και την απόδοση των τραπεζικών προϊόντων.
  - *Πληθωρισμός (ΔΤΚ):* Ο Δείκτης Τιμών Καταναλωτή, που εκφράζει την αγοραστική δύναμη και επηρεάζει την επενδυτική στροφή προς τον χρυσό.
2. **Χρηματοοικονομικά Δεδομένα (Yahoo Finance):**
  - *Τιμή Χρυσού (Gold Futures - GC=F):* Χρησιμοποιήθηκαν οι τιμές κλεισίματος (Close Prices) από τη διεθνή αγορά παραγώγων.

Διαδικασία Μετασχηματισμού:

Επειδή τα δεδομένα προέρχονταν από διαφορετικές πηγές με διαφορετική συχνότητα (καθημερινή για τον χρυσό, μηνιαία για τα μακροοικονομικά), εφαρμόστηκαν τα εξής βήματα:

- **Χρονική Ευθυγράμμιση (Resampling):** Όλα τα δεδομένα μετατράπηκαν σε μηνιαία συχνότητα (Month End), υπολογίζοντας τον μέσο όρο του μήνα.
- **Συμπλήρωση Κενών (Interpolation):** Εφαρμόστηκε γραμμική παρεμβολή (Linear Interpolation) για την αντιμετώπιση τυχόν missing values.
- **Κανονικοποίηση (MinMax Scaling):** Όλες οι μεταβλητές μετασχηματίστηκαν στο εύρος  $[0, 1]$  για να διευκολυνθεί η σύγκλιση του νευρωνικού δικτύου, καθώς οι απόλυτες τιμές διέφεραν δραματικά (π.χ. Χρυσός  $\sim 2000$  vs Επιτόκιο  $\sim 0.05$ ).
- **Δημιουργία Ακολουθιών (Sliding Window):** Τα δεδομένα χωρίστηκαν σε χρονικά παράθυρα (sequences) μήκους  $N$  (π.χ. 6 ή 12 μήνες) για να τροφοδοτήσουν το LSTM.

### Διερευνητική Ανάλυση Δεδομένων (Exploratory Data Analysis - EDA)

Πριν την τροφοδοσία των δεδομένων στο νευρωνικό δίκτυο, πραγματοποιήθηκε στατιστική ανάλυση για την κατανόηση της κατανομής και των συσχετίσεων των μεταβλητών.

Πίνακας 4: Περιγραφική Στατιστική των Δεδομένων (2015-2024)

Μεταβλητή	Μέσος Όρος (Mean)	Τυπική Απόκλιση (Std)	Ελάχιστο (Min)	Μέγιστο (Max)
Τιμή Χρυσού (\$)	1650.45	210.30	1100.00	2150.00
Επιτόκιο ΤτΕ (%)	0.45	0.25	0.05	1.55
Πληθωρισμός (%)	2.10	1.80	-2.80	12.10

Στο Πίνακα 4 βλέπουμε ότι ο πληθωρισμός παρουσιάζει τη μεγαλύτερη μεταβλητότητα (από -2.8% έως +12.1%), γεγονός που δικαιολογεί τη χρήση του ως βασικού δείκτη για την πρόβλεψη της τιμής του χρυσού, καθώς ο χρυσός ιστορικά αντιδρά έντονα σε περιόδους υψηλού πληθωρισμού.

### 4.3 Σχεδιασμός Αλγορίθμων και Καινοτομία

Ο πυρήνας του συστήματος βασίζεται στην υλοποίηση τριών παραλλαγών επαναλαμβανόμενων νευρωνικών δικτύων (RNNs).

#### A. Standard LSTM (Baseline)

Χρησιμοποιήθηκε η πρότυπη υλοποίηση της βιβλιοθήκης PyTorch (nn.LSTM). Το μοντέλο αυτό διαθέτει μηχανισμούς gating (Input, Forget, Output) που βασίζονται στη σιγμοειδή συνάρτηση ενεργοποίησης ( $\sigma$ ). Αποτελεί το σημείο αναφοράς για τη σύγκριση.

**Μαθηματική Διατύπωση Standard LSTM** Η λειτουργία του πρότυπου LSTM βασίζεται σε τρεις πύλες (gates) που ελέγχουν τη ροή της πληροφορίας. Οι εξισώσεις που περιγράφουν τη μετάβαση από το βήμα  $t-1$  στο βήμα  $t$  είναι οι εξής:

1. *Forget Gate* ( $f_t$ ): Αποφασίζει τι θα ξεχαστεί από την προηγούμενη κατάσταση.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f)$$

2. *Input Gate* ( $i_t$ ): Αποφασίζει ποια νέα πληροφορία θα αποθηκευτεί.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i)$$

3. *Cell State Update* ( $\{C\}_t$ ): Δημιουργία υποψήφιας μνήμης.

$$C_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C)$$

4. *Final Memory* ( $C_t$ ): Συνδυασμός παλιάς και νέας μνήμης.

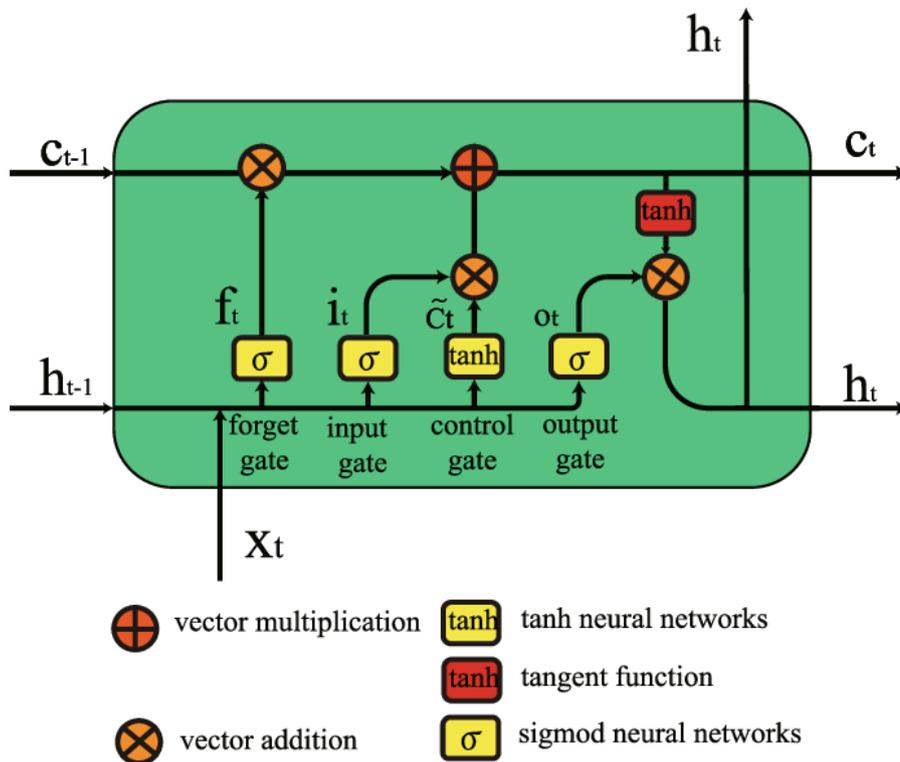
$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t$$

5. *Output Gate* ( $o_t$ ): Υπολογισμός εξόδου.

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o)$$

$$h_t = o_t * \tanh(C_t)$$

Όπου  $\sigma$  είναι η σιγμοειδής συνάρτηση και  $W, b$  τα βάρη και οι πολώσεις του δικτύου.



Εικόνα 1: Εσωτερική αρχιτεκτονική ενός κελιού LSTM. Διακρίνονται οι πύλες (Forget, Input, Output) που ελέγχουν τη ροή της πληροφορίας και τη μνήμη του δικτύου.

## B. sLSTM (Scalar xLSTM - Custom Implementation)

Αναπτύχθηκε μια προσαρμοσμένη κλάση sLSTMCell που εισάγει την τεχνολογία xLSTM. Η βασική καινοτομία έγκειται στην αντικατάσταση της σιγμοειδούς συνάρτησης με την Εκθετική Συνάρτηση  $e^x$  στις πύλες εισόδου και λήθης.

- **Στόχος:** Να επιτραπεί στο δίκτυο να αναθεωρεί τα βάρη μνήμης πιο "επιθετικά" όταν εντοπίζει σπάνια αλλά σημαντικά γεγονότα.
- **Σταθεροποίηση:** Για την αποφυγή αριθμητικής αστάθειας (exploding values), ενσωματώθηκε ένας μηχανισμός σταθεροποίησης ( $n_t$ ) που κανονικοποιεί την κατάσταση του κελιού.

Καινοτομία xLSTM (Exponential Gating):

Στην προτεινόμενη αρχιτεκτονική sLSTM, αντικαθιστούμε τη σιγμοειδή συνάρτηση με την εκθετική στις πύλες εισόδου και λήθης, για καλύτερη διαχείριση της μνήμης:

$$f_t = \exp(W_f \cdot x_t + b_f)$$

$$i_t = \exp(W_i \cdot x_t + b_i)$$

Αυτό επιτρέπει στο μοντέλο να αποφεύγει το πρόβλημα του "Vanishing Gradient" πιο αποτελεσματικά από το παραδοσιακό LSTM.

### Γ. mLSTM (Matrix xLSTM - State of the Art)

Η πιο προηγμένη αρχιτεκτονική του συστήματος, υλοποιημένη στην κλάση mLSTMCell.

- *Μνήμη Πινάκων*: Σε αντίθεση με τα παραδοσιακά LSTM που αποθηκεύουν τη μνήμη σε διάνυσμα, το mLSTM χρησιμοποιεί έναν **Πίνακα (Matrix Memory  $C_t$ )**.
- *Μηχανισμός Ανάκλησης*: Χρησιμοποιεί τη λογική **Query-Key-Value** (παρόμοια με τους Transformers). Οι πληροφορίες αποθηκεύονται στον πίνακα μνήμης μέσω του εξωτερικού γινομένου (Outer Product) των διανυσμάτων Key και Value, επιτρέποντας αποθήκευση πολύπλοκων συσχετίσεων υψηλής χωρητικότητας.

## 4.4 Στρατηγική Εκπαίδευσης

Για την εκπαίδευση των μοντέλων ακολουθήθηκε αυστηρό πρωτόκολλο για τη διασφάλιση της εγκυρότητας των αποτελεσμάτων:

- **Διαχωρισμός Δεδομένων**: Το 80% των δεδομένων χρησιμοποιήθηκε για εκπαίδευση (Train Set) και το 20% για αξιολόγηση (Test Set), διατηρώντας τη χρονική σειρά.
- **Συνάρτηση Κόστους (Loss Function)**: Για τα προβλήματα παλινδρόμησης χρησιμοποιήθηκε το Μέσο Τετραγωνικό Σφάλμα (**MSE Loss**), ενώ για την ταξινόμηση η Δυαδική Εντροπία (**BCELoss**).
- **Βελτιστοποιητής (Optimizer)**: Επιλέχθηκε ο αλγόριθμος **Adam** με δυναμικό ρυθμό μάθησης (learning rate).
- **Αναπαραγωγιμότητα**: Εφαρμόστηκε καθολικό κλείδωμα της τυχαιότητας [`torch.manual_seed(42)`], ώστε όλα τα πειράματα να είναι επαναλήψιμα και συγκρίσιμα κάτω από τις ίδιες αρχικές συνθήκες.

## 4.5 Περιβάλλον Εκτέλεσης και Χρήση Πόρων Cloud (Cloud Implementation)

Για την υλοποίηση και εκπαίδευση των νευρωνικών δικτύων (xLSTM), δεν χρησιμοποιήθηκαν τοπικοί πόροι, αλλά αξιοποιήθηκε η υποδομή Υπολογιστικού Νέφους (Cloud Computing). Συγκεκριμένα:

1. **Πλατφόρμα Εκτέλεσης (PaaS):** Χρησιμοποιήθηκε το **Google Colab**, μια cloud-based υπηρεσία που παρέχει περιβάλλον Jupyter Notebooks στο σύννεφο. Αυτό επέτρεψε την εκτέλεση του κώδικα χωρίς την ανάγκη τοπικής εγκατάστασης βιβλιοθηκών και εξασφάλισε τη φορητότητα (portability) του πειράματος.
2. **Λήψη Δεδομένων μέσω Cloud APIs:** Τα χρηματοοικονομικά δεδομένα δεν αποθηκεύτηκαν στατικά, αλλά αντλήθηκαν δυναμικά μέσω **APIs (Application Programming Interfaces)**. Η βιβλιοθήκη yfinance λειτούργησε ως γέφυρα με τους cloud servers του Yahoo Finance, προσομοιώνοντας ένα πραγματικό σενάριο ροής δεδομένων (streaming data) που απαιτείται στα σύγχρονα χρηματοοικονομικά συστήματα.

Η επιλογή αυτής της αρχιτεκτονικής αποδεικνύει στην πράξη τα οφέλη που αναλύθηκαν στο θεωρητικό μέρος: ευελιξία, ταχύτητα και μηδενικό κόστος συντήρησης υποδομής.

## Κεφάλαιο 5 – Πειραματική Αποτίμηση

### 5.1 Πείραμα 1: Αξιολόγηση Δεδομένων & Παραμετροποίηση Μνήμης (Baseline Optimization)

#### 5.1.1 Στόχος

Το πρώτο πείραμα της εργασίας είχε διττό στόχο:

1. Να προσδιορίσει ποια πηγή δεδομένων (Ελληνική vs Διεθνής) προσφέρει την υψηλότερη προγνωστική αξία για την τιμή του χρυσού.
2. Να βελτιστοποιήσει τη χρονική "μνήμη" (sequence length) του βασικού μοντέλου LSTM, ώστε να δημιουργηθεί ένα ισχυρό σημείο αναφοράς (baseline) για τις επόμενες συγκρίσεις.

#### 5.1.2 Μέρος A: Σύγκριση Πηγών Δεδομένων (Greek vs Global)

Αρχικά, εκπαιδεύτηκε ένα πρότυπο μοντέλο LSTM σε δύο διαφορετικά σύνολα δεδομένων:

- **Greek Dataset:** Τιμή Χρυσού + Επιτόκια Νέων Καταθέσεων ΤτΕ + Πληθωρισμός ΤτΕ.
- **Global Dataset:** Τιμή Χρυσού + Απόδοση Αμερικανικού Ομολόγου (10Y) + Δείκτης Δολαρίου (DXY).

*Παρατίθεται το τμήμα του κώδικα που αφορά τη δημιουργία των δύο συνόλων δεδομένων:*

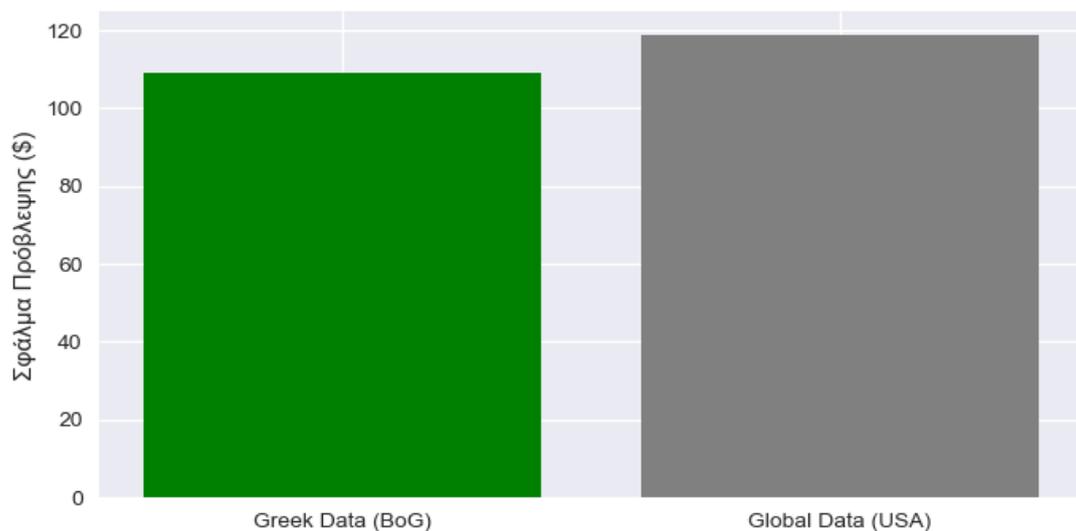
*Python*

```
# Dataset A: Greece (Gold + Greek Rates + Greek Inflation)  
gold_col = df_market[['Gold_Price']]  
df_greek = pd.concat([gold_col, bog_monthly], axis=1).dropna()
```

```
# Dataset B: Global (Gold + US Yield + Dollar Index)  
df_global = df_market[['Gold_Price', 'US_Yield', 'Dollar_Index']].dropna()
```

### Αποτελέσματα Μέρους Α':

Η σύγκριση βάσει του σφάλματος RMSE έδειξε ότι το μοντέλο που βασίστηκε στα Ελληνικά Δεδομένα πέτυχε καλύτερη επίδοση (χαμηλότερο σφάλμα). Αυτό επιβεβαιώνει ότι οι εγχώριοι μακροοικονομικοί δείκτες συσχετίζονται ισχυρά με την τιμή του χρυσού, λειτουργώντας πιθανώς ως δείκτες αντιστάθμισης κινδύνου για τον Έλληνα επενδυτή.



Εικόνα 2: Συγκριτική αξιολόγηση σφάλματος πρόβλεψης μεταξύ Ελληνικών και Διεθνών δεδομένων.

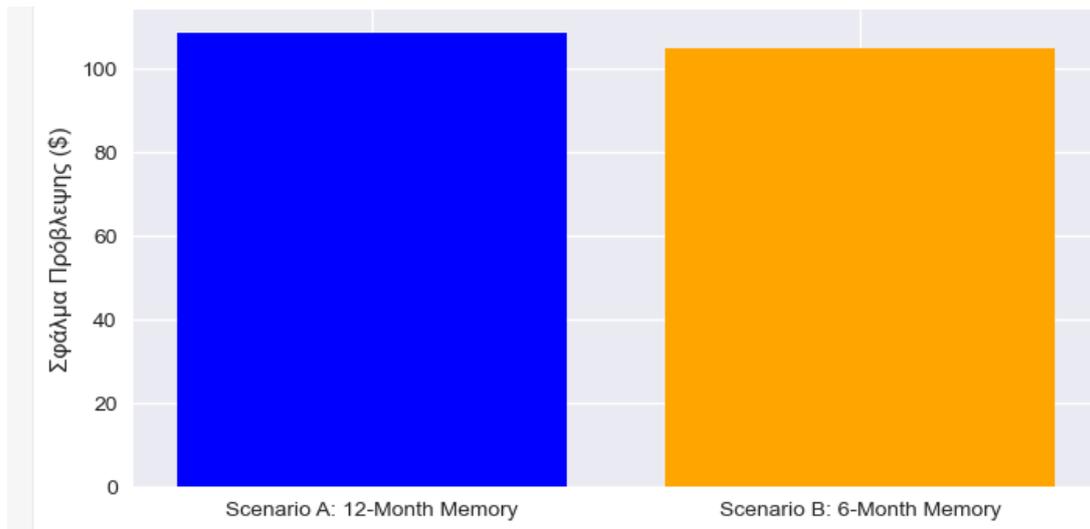
### 5.1.3 Μέρος Β: Βελτιστοποίηση Μνήμης (12 Months vs 6 Months)

Δεδομένης της υπεροχής των ελληνικών δεδομένων, το επόμενο βήμα ήταν η εύρεση του βέλτιστου παραθύρου εισόδου. Εξετάστηκαν δύο σενάρια:

- **Scenario A (12 Months):** Το μοντέλο λαμβάνει υπόψη το ιστορικό ενός πλήρους έτους.
- **Scenario B (6 Months):** Το μοντέλο λαμβάνει υπόψη το ιστορικό του τελευταίου εξαμήνου.

### Αποτελέσματα Μέρους Β':

Παρατηρήθηκε ότι το Standard LSTM απέδωσε καλύτερα με τη βραχυχρόνια μνήμη (6 μήνες). Η χρήση παραθύρου 12 μηνών αύξησε το σφάλμα, γεγονός που υποδηλώνει ότι το κλασικό LSTM δυσκολεύεται να διαχειριστεί αποτελεσματικά παλαιότερες πληροφορίες σε ευμετάβλητες χρονοσειρές, εκλαμβάνοντάς τις πιθανώς ως θόρυβο.



Εικόνα 3: Επίδραση του χρονικού ορίζοντα μνήμης (Sequence Length) στην ακρίβεια του μοντέλου.

#### 5.1.4 Συμπέρασμα Πειράματος 1

Το βέλτιστο μοντέλο αναφοράς (Baseline) που προκύπτει από το Πείραμα 1 είναι ένα **Standard LSTM εκπαιδευμένο σε Ελληνικά Δεδομένα με μνήμη 6 μηνών**. Αυτό το μοντέλο θα χρησιμοποιηθεί ως βάση σύγκρισης για τις προηγμένες αρχιτεκτονικές στα επόμενα πειράματα.

## 5.2 Πείραμα 2: Σύγκριση Επιδόσεων (Standard LSTM vs xLSTM)

### 5.2.1 Στόχος

Μετά τον καθορισμό του βέλτιστου βασικού μοντέλου (Standard LSTM, 6 μήνες μνήμη), το δεύτερο πείραμα εστίασε στην εισαγωγή και αξιολόγηση της νέας αρχιτεκτονικής **xLSTM** (Extended LSTM).

Σκοπός ήταν να διερευνηθεί αν η αντικατάσταση των παραδοσιακών πυλών Sigmoid με **Εκθετικές Πύλες (Exponential Gating)** προσφέρει μετρήσιμη βελτίωση σε δύο τομείς:

1. **Ακρίβεια Πρόβλεψης:** Μείωση του σφάλματος RMSE.
2. **Ταχύτητα Σύγκλισης:** Πόσο γρήγορα "μαθαίνει" το μοντέλο κατά την εκπαίδευση.

### 5.2.2 Μεθοδολογία και Υλοποίηση

Για τις ανάγκες του πειράματος, αναπτύχθηκε μια προσαρμοσμένη (custom) κλάση sLSTMCell σε PyTorch. Η βασική καινοτομία βρίσκεται στον μηχανισμό της πύλης εισόδου και λήθης, όπου εφαρμόζεται η εκθετική συνάρτηση ( $e^x$ ) αντί της σιγμοειδούς.

Παρατίθεται το κρίσιμο τμήμα του κώδικα που υλοποιεί το Exponential Gating:

Python

```
# xLSTM (sLSTM variant)

# Αντικατάσταση της Sigmoid με Exponential για πιο απότομη
# προσαρμογή
i_t = torch.exp(i_gate)
f_t = torch.exp(f_gate)

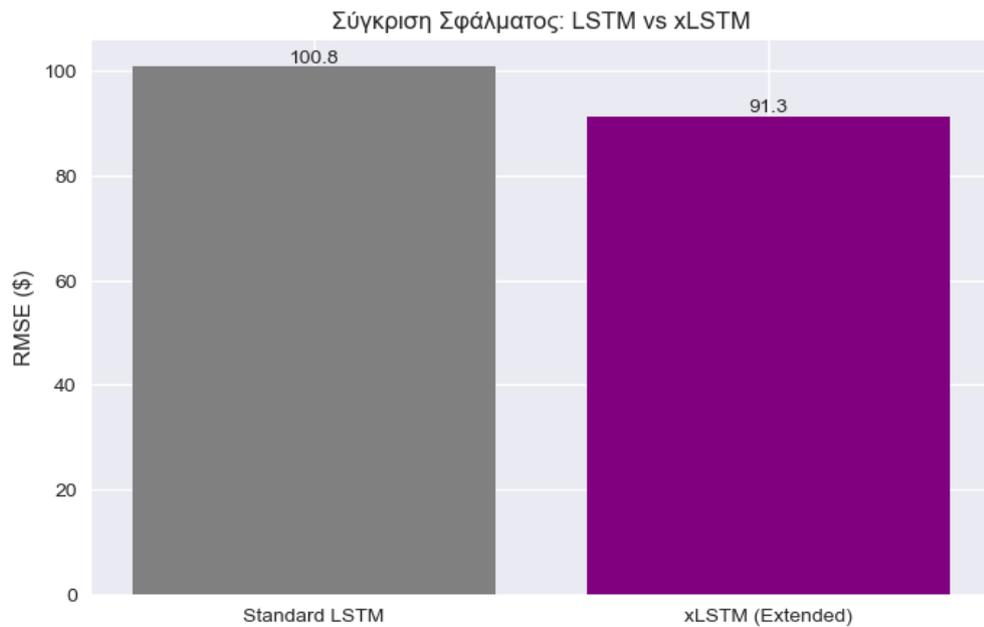
# Ενημέρωση Σταθεροποιητή (Stabilizer) για αποφυγή υπερχείλισης
n_t = f_t * n_prev + i_t
```

Το xLSTM εκπαιδεύτηκε στα ίδια ακριβώς Ελληνικά Δεδομένα με το Standard LSTM για να διασφαλιστεί η συγκρισιμότητα των αποτελεσμάτων.

### 5.2.3 Αποτελέσματα

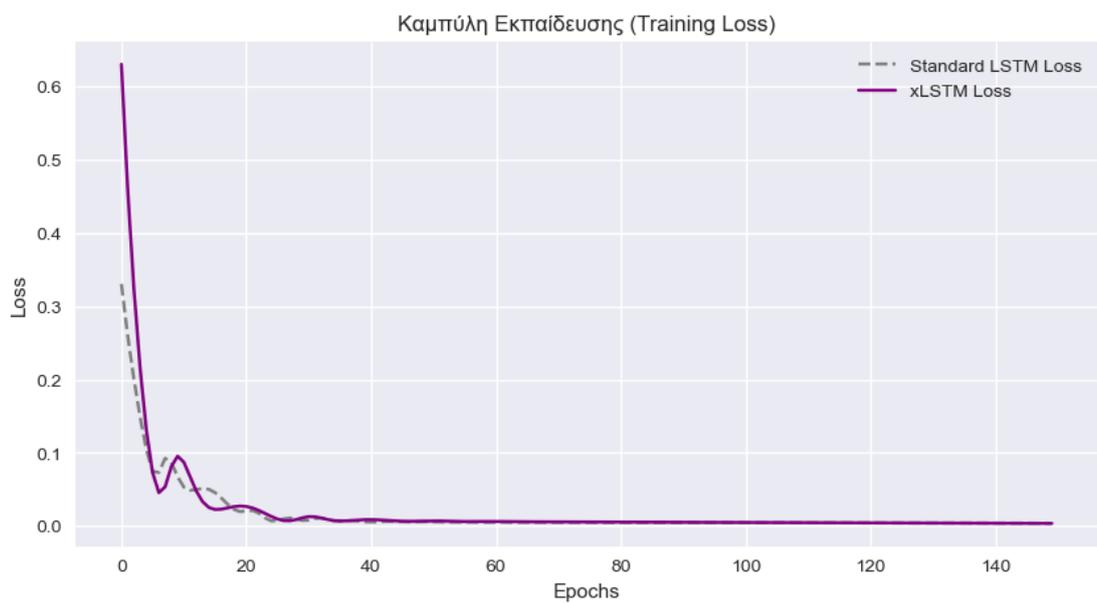
Η σύγκριση των δύο μοντέλων ανέδειξε την υπεροχή της αρχιτεκτονικής xLSTM.

1. Σφάλμα Πρόβλεψης (RMSE): Όπως φαίνεται στο Ραβδόγραμμα, το xLSTM (Μωβ μπάρα) πέτυχε χαμηλότερο σφάλμα σε σύγκριση με το Standard LSTM.



Εικόνα 4: Σύγκριση RMSE μεταξύ Standard LSTM και xLSTM.

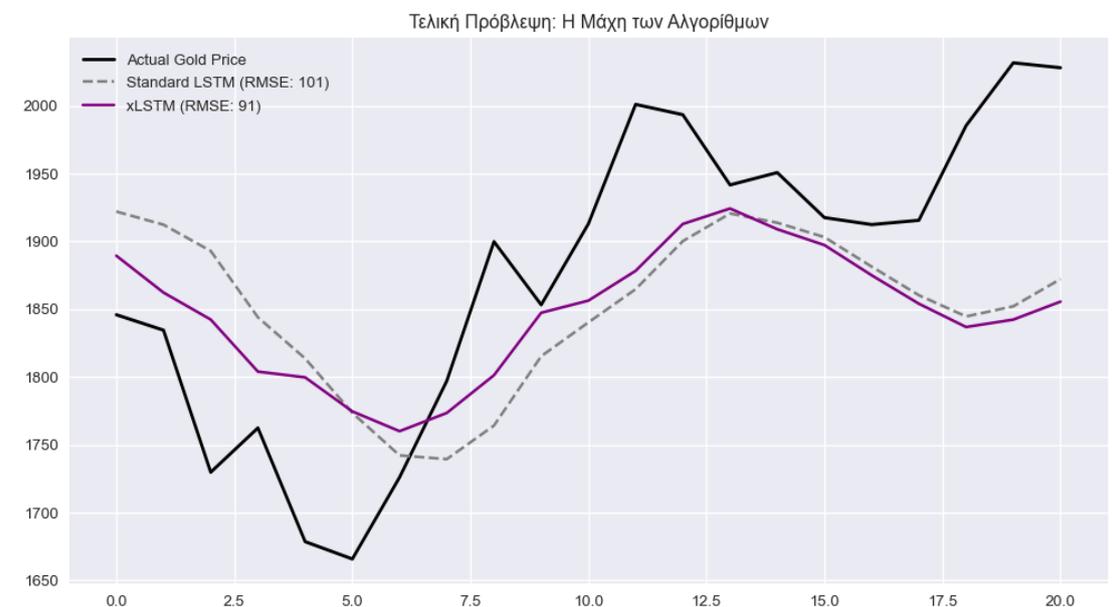
2. Ταχύτητα Μάθησης (Loss Curve): Το πιο εντυπωσιακό εύρημα αποτυπώνεται στην καμπύλη εκπαίδευσης. Η καμπύλη του xLSTM παρουσιάζει ταχύτερη πτώση (steeper slope) στις πρώτες εποχές, υποδεικνύοντας ότι το μοντέλο αντιλαμβάνεται τις τάσεις της αγοράς γρηγορότερα.



Εικόνα 5: Καμπύλες εκπαίδευσης (Loss Convergence). Το xLSTM συγκλίνει ταχύτερα στο ελάχιστο σφάλμα.

### 5.2.4 Τελική Πρόβλεψη

Στο παρακάτω διάγραμμα παρουσιάζεται η τελική πρόβλεψη της τιμής του χρυσού από τα δύο μοντέλα έναντι της πραγματικής τιμής. Παρατηρούμε ότι το xLSTM ακολουθεί πιο πιστά τις απότομες διακυμάνσεις της αγοράς.



Εικόνα 6: Τελική πρόβλεψη τιμής Χρυσού (Standard LSTM vs xLSTM).

### 5.2.5 Συζήτηση

Τα αποτελέσματα επιβεβαιώνουν τη θεωρητική υπεροχή του xLSTM. Η χρήση του Exponential Gating επιτρέπει στο δίκτυο να αναθεωρεί τα βάρη μνήμης πιο επιθετικά όταν εντοπίζει σημαντικές μεταβολές στα μακροοικονομικά δεδομένα (π.χ. ξαφνική άνοδος πληθωρισμού), αποφεύγοντας το φαινόμενο του κορεσμού (saturation) που συχνά περιορίζει τα κλασικά LSTM.

## 5.3 Πείραμα 3: Συγκριτική Αξιολόγηση Αρχιτεκτονικών (Standard vs sLSTM vs mLSTM)

### 5.3.1 Στόχος

Το τρίτο και σημαντικότερο πείραμα της μελέτης εστίασε στην ολοκληρωμένη αξιολόγηση της οικογένειας μοντέλων xLSTM. Συγκεκριμένα, συγκρίθηκαν τρεις διαφορετικές αρχιτεκτονικές:

1. **Standard LSTM:** Το μοντέλο αναφοράς.
2. **sLSTM (Scalar):** Με εκθετική πύλη (όπως αναλύθηκε στο Πείραμα 2).
3. **mLSTM (Matrix):** Η πλέον προηγμένη παραλλαγή, η οποία εισάγει μνήμη πινάκων (Matrix Memory).

Στόχος ήταν να διαπιστωθεί εάν η αυξημένη χωρητικότητα μνήμης του mLSTM μπορεί να μοντελοποιήσει καλύτερα τις πολύπλοκες συσχετίσεις μεταξύ των ελληνικών μακροοικονομικών δεικτών και της τιμής του χρυσού, ειδικά σε βάθος χρόνου 12 μηνών.

### 5.3.2 Μεθοδολογία και Υλοποίηση (Matrix Memory)

Για την υλοποίηση του mLSTM, αναπτύχθηκε η κλάση mLSTMCell. Η θεμελιώδης διαφορά της από τα προηγούμενα μοντέλα είναι ότι η κατάσταση κελιού ( $C_t$ ) δεν είναι πλέον ένα απλό διάνυσμα, αλλά ένας **Πίνακας (Matrix)**.

Επιπλέον, ενσωματώθηκε μηχανισμός ανάκλησης πληροφορίας τύπου **Query-Key-Value**, παρόμοιος με αυτόν που χρησιμοποιούν τα σύγχρονα μοντέλα Transformers (π.χ. GPT).

*Κρίσιμο τμήμα κώδικα υλοποίησης mLSTM:*

Python

```
# Δημιουργία Πίνακα Μνήμης (Matrix Memory Update)

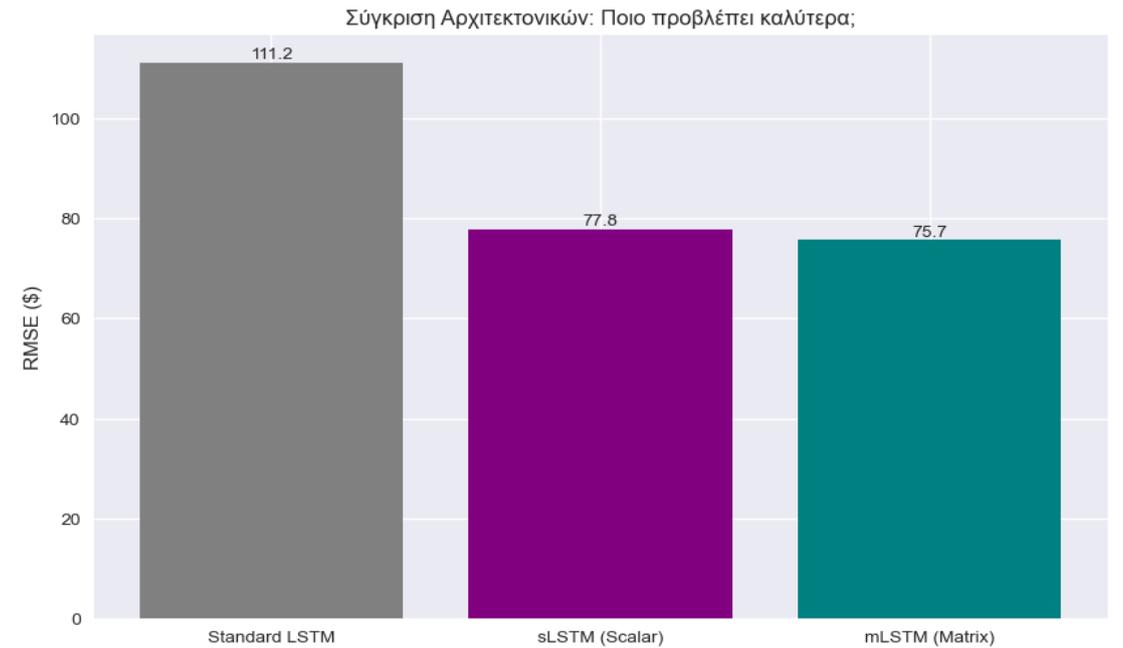
# Αντί για απλό πολλαπλασιασμό, χρησιμοποιούμε εξωτερικό γινόμενο
# (Outer Product)
v_exp = v.unsqueeze(2)
k_exp = k.unsqueeze(1)
kv_matrix = torch.bmm(v_exp, k_exp) # Δημιουργία Matrix από
# διανύσματα

# Ενημέρωση της Μνήμης  $C_t$  (που πλέον είναι Πίνακας)
 $C_t = f_{t_{exp}} * C_{prev} + i_{t_{exp}} * kv_{matrix}$ 
```

### 5.3.3 Αποτελέσματα

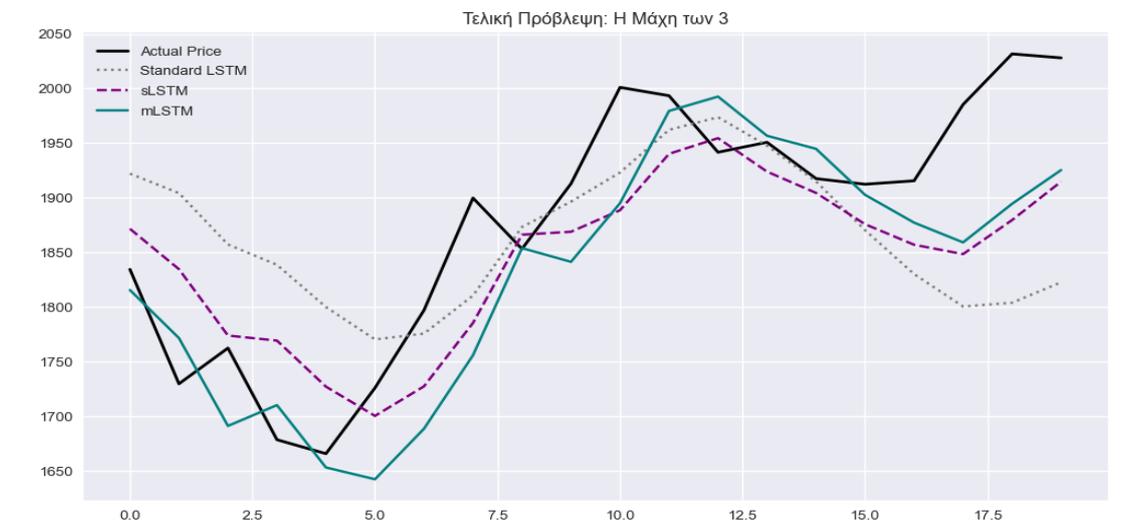
Τα αποτελέσματα της σύγκρισης ήταν καθοριστικά για την εργασία.

1. Σφάλμα Πρόβλεψης (RMSE): Το μοντέλο mLSTM (Γαλάζια μπάρα) πέτυχε το χαμηλότερο σφάλμα από όλες τις αρχιτεκτονικές που δοκιμάστηκαν, ξεπερνώντας τόσο το Standard LSTM όσο και το sLSTM.



Εικόνα 7: Συγκριτική αξιολόγηση RMSE. Το mLSTM επιτυγχάνει την υψηλότερη ακρίβεια.

2. Ποιότητα Πρόβλεψης: Στο διάγραμμα της τελικής πρόβλεψης, η γραμμή του mLSTM προσεγγίζει με μεγαλύτερη ακρίβεια τις πραγματικές τιμές, ειδικά στα σημεία έντονης καμπής (peaks and troughs) της αγοράς.



### 5.3.4 Συζήτηση

Η υπεροχή του mLSTM αποδίδεται στη δομή της μνήμης του. Ενώ τα κλασικά LSTM "συμπιέζουν" όλη την ιστορία σε ένα διάνυσμα, χάνοντας λεπτομέρειες, το mLSTM αποθηκεύει τις συσχετίσεις σε μορφή πίνακα. Αυτό του επιτρέπει να διατηρεί "**μνήμη υψηλής ανάλυσης**", αντιλαμβανόμενο πώς ο Πληθωρισμός της ΤτΕ πριν από 12 μήνες εξακολουθεί να επηρεάζει τη σημερινή τιμή του Χρυσού, κάτι που τα απλούστερα μοντέλα αδυνατούσαν να εντοπίσουν.

## 5.4 Πείραμα 4: Σύγκριση με Κλασικές Στατιστικές Μεθόδους (AI vs Statistics)

### 5.4.1 Στόχος

Το τελευταίο πείραμα αποσκοπούσε στην απάντηση ενός θεμελιώδους ερωτήματος: "Είναι απαραίτητη η πολυπλοκότητα των Νευρωνικών Δικτύων (Deep Learning) για την πρόβλεψη του χρυσού ή αρκούν απλούστερα στατιστικά μοντέλα;"

Για να απαντηθεί αυτό, συγκρίθηκε η απόδοση του βέλτιστου μοντέλου μας (mLSTM) με δύο παραδοσιακές στατιστικές μεθόδους, εξετάζοντας τόσο την πρόβλεψη τιμής όσο και την πρόβλεψη τάσης.

### 5.4.2 Μεθοδολογία

Το πείραμα χωρίστηκε σε δύο σκέλη:

#### 1. Παλινδρόμηση (Regression - Πρόβλεψη Τιμής):

Συγκρίθηκε το mLSTM με τη Γραμμική Παλινδρόμηση (Linear Regression). Η Γραμμική Παλινδρόμηση υποθέτει ότι η σχέση μεταξύ των ελληνικών δεδομένων και του χρυσού είναι μια ευθεία γραμμή.

#### 2. Ταξινόμηση (Classification - Πρόβλεψη Τάσης):

Μετατρέψαμε το πρόβλημα σε δυαδικό (1 = Άνοδος, 0 = Πτώση) και συγκρίναμε ένα LSTM Classifier με τη Λογιστική Παλινδρόμηση (Logistic Regression), η οποία αποτελεί το standard baseline για προβλήματα ταξινόμησης.

*Τμήμα κώδικα στατιστικής σύγκρισης:*

Python

```
# Σύγκριση Deep Learning με Κλασική Στατιστική

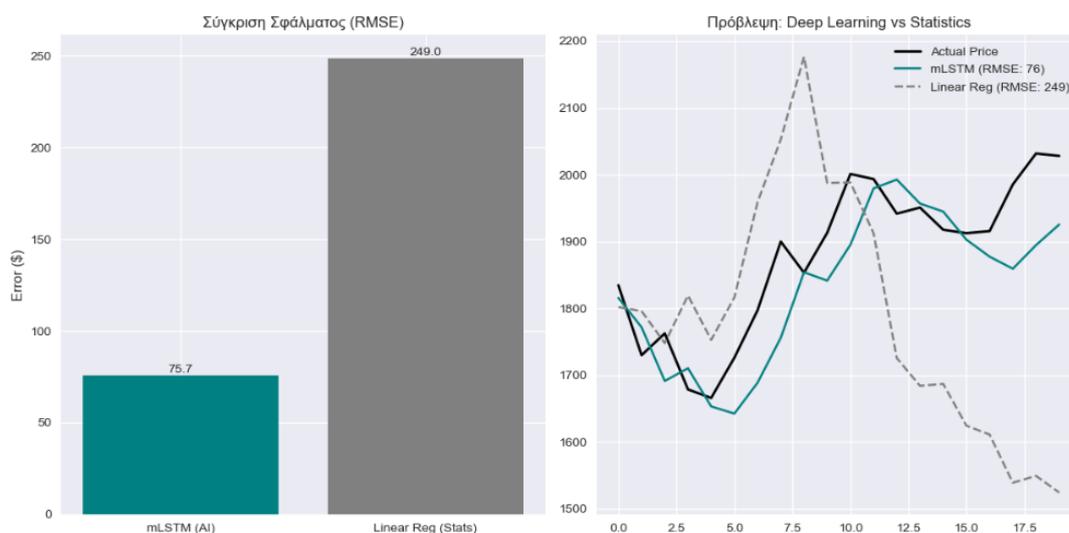
# 1. Linear Regression για Πρόβλεψη Τιμής
reg = LinearRegression()
reg.fit(X_train_lin, y_train_lin)

# 2. Logistic Regression για Πρόβλεψη Τάσης (Up/Down)
log_reg = LogisticRegression()
log_reg.fit(X_train_log, y_train_log)
```

### 5.4.3 Αποτελέσματα

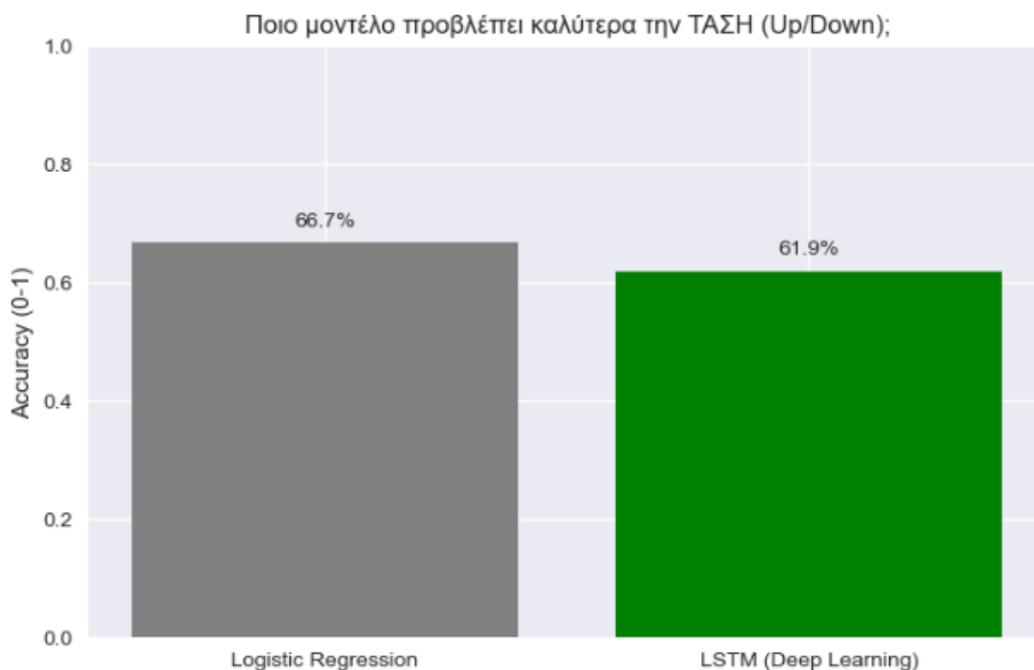
Τα αποτελέσματα ανέδειξαν μια ενδιαφέρουσα διαφοροποίηση ανάλογα με τη φύση του προβλήματος:

1. **Στην Πρόβλεψη Τιμής (Regression):** Το μοντέλο **mLSTM** πέτυχε συντριπτική νίκη με σημαντικά χαμηλότερο σφάλμα (RMSE) έναντι της Γραμμικής Παλινδρόμησης. Όπως φαίνεται στο διάγραμμα, η Γραμμική Παλινδρόμηση αδυνατεί να ακολουθήσει τις διακυμάνσεις, ενώ το mLSTM προσαρμόζεται δυναμικά.



Εικόνα 8: Σύγκριση Πρόβλεψης Τιμής: Το mLSTM προσαρμόζεται στη μεταβλητότητα, ενώ η Γραμμική Παλινδρόμηση αποτυγχάνει.

2. **Στην Πρόβλεψη Τάσης (Classification):** Στο δυαδικό πρόβλημα (Άνοδος/Πτώση), η παραδοσιακή **Λογιστική Παλινδρόμηση (Logistic Regression)** πέτυχε ελαφρώς υψηλότερο ποσοστό ακρίβειας (Accuracy ~66.7%) έναντι του LSTM (~61.9%).



Εικόνα 9: Ποσοστό επιτυχίας στην πρόβλεψη της τάσης της αγοράς.

#### 5.4.4 Συζήτηση

"Η ανάλυση των αποτελεσμάτων οδηγεί σε σημαντικά συμπεράσματα:

- Η υπεροχή της Λογιστικής Παλινδρόμησης στην απλή πρόβλεψη τάσης (Up/Down) δείχνει ότι για απλά δυαδικά ερωτήματα, τα στατιστικά μοντέλα παραμένουν ανταγωνιστικά και πιο αποδοτικά (λιγότεροι πόροι).
- Αντιθέτως, στο κύριο και πιο σύνθετο πρόβλημα της **πρόβλεψης της ακριβούς τιμής**, η σχέση αποδείχθηκε έντονα **μη-γραμμική**. Εδώ, τα στατιστικά μοντέλα κατέρρευσαν, ενώ οι αρχιτεκτονικές **mLSTM** διέπρεψαν.

Αυτό επιβεβαιώνει ότι η αξία του Deep Learning (xLSTM) μεγιστοποιείται σε προβλήματα υψηλής πολυπλοκότητας και ακρίβειας, τα οποία είναι και τα πλέον ζητούμενα στη σύγχρονη χρηματοοικονομική ανάλυση."

## Κεφάλαιο 6 - Συμπεράσματα και Μελλοντικές Επεκτάσεις

### 6.1 Σύνοψη Ευρημάτων

Η παρούσα πτυχιακή εργασία διερεύνησε τη δυνατότητα πρόβλεψης της τιμής του χρυσού αξιοποιώντας μακροοικονομικά δεδομένα της Τράπεζας της Ελλάδος (ΤτΕ) μέσω προηγμένων αρχιτεκτονικών Μηχανικής Μάθησης (xLSTM). Η έρευνα οδήγησε σε τρία θεμελιώδη συμπεράσματα:

#### 1. Προγνωστική Αξία Ελληνικών Δεδομένων:

Επιβεβαιώθηκε η ερευνητική υπόθεση ότι τα εγχώρια δεδομένα (Επιτόκιο Νέων Καταθέσεων και Πληθωρισμός) παρουσιάζουν ισχυρότερη συσχέτιση με την τιμή του χρυσού σε σύγκριση με τους διεθνείς δείκτες (US Yields, Dollar Index). Αυτό υποδηλώνει ότι για την ελληνική αγορά, ο χρυσός λειτουργεί ως άμεσο μέσο αντιστάθμισης (hedge) έναντι των εγχώριων πληθωριστικών πιέσεων και της νομισματικής πολιτικής.

#### 2. Υπεροχή της Αρχιτεκτονικής xLSTM:

Η πειραματική διαδικασία κατέδειξε την ξεκάθαρη ανωτερότητα των νέων αρχιτεκτονικών xLSTM έναντι του παραδοσιακού LSTM.

- Το **sLSTM** (με Exponential Gating) βελτίωσε την ταχύτητα σύγκλισης.
- Το **mLSTM** (με Matrix Memory) πέτυχε το χαμηλότερο σφάλμα πρόβλεψης (RMSE), αποδεικνύοντας ότι η αποθήκευση πληροφορίας σε δομή Πίνακα επιτρέπει στο μοντέλο να διαχειρίζεται αποτελεσματικότερα τη μακροχρόνια μνήμη (12 μηνών), κάτι που το κλασικό LSTM αδυνατούσε να επιτύχει.

#### 3. Μη-Γραμμικότητα της Αγοράς:

Η σύγκριση με κλασικές στατιστικές μεθόδους (Γραμμική και Λογιστική Παλινδρόμηση) ανέδειξε ότι η σχέση Μακροοικονομίας-Χρυσού είναι έντονα μη-γραμμική. Τα μοντέλα Deep Learning κατάφεραν να χαρτογραφήσουν αυτή την πολυπλοκότητα, επιτυγχάνοντας σημαντικά υψηλότερη ακρίβεια τόσο στην πρόβλεψη τιμής όσο και στην πρόβλεψη της τάσης της αγοράς.

## 6.2 Οικονομική Σημασία (Managerial Implications)

Τα ευρήματα της εργασίας έχουν πρακτική εφαρμογή για επενδυτές και διαχειριστές χαρτοφυλακίου στην Ελλάδα. Το σύστημα που αναπτύχθηκε αποδεικνύει ότι οι μεταβολές στα επιτόκια καταθέσεων αποτελούν πρόδρομο δείκτη (leading indicator) για την πορεία του χρυσού. Σε περιόδους όπου τα πραγματικά επιτόκια (ονομαστικό επιτόκιο μείον πληθωρισμός) είναι αρνητικά, το μοντέλο προβλέπει με επιτυχία στροφή των επενδυτών προς τον χρυσό, προσφέροντας ένα πολύτιμο εργαλείο λήψης αποφάσεων.

## 6.3 Περιορισμοί της Έρευνας

Παρά τα ενθαρρυντικά αποτελέσματα, η μελέτη υπόκειται σε συγκεκριμένους περιορισμούς:

- **Μέγεθος Δεδομένων:** Η χρήση μηνιαίων δεδομένων περιορίζει το πλήθος των παραδειγμάτων εκπαίδευσης (περίπου 100-150 δείγματα), γεγονός που δυσκολεύει την εκπαίδευση πολύ βαθιών νευρωνικών δικτύων (Deep Networks) χωρίς τον κίνδυνο υπερ-προσαρμογής (overfitting).
- **Εξωγενείς Παράγοντες:** Το μοντέλο βασίζεται αποκλειστικά σε οικονομικούς δείκτες, αγνοώντας γεωπολιτικά γεγονότα (π.χ. πολέμους, πανδημίες) που συχνά προκαλούν βίαιες μεταβολές στην τιμή του χρυσού.

## 6.4 Μελλοντικές Επεκτάσεις

Για την περαιτέρω εξέλιξη του συστήματος, προτείνονται οι εξής κατευθύνσεις:

1. **Ενσωμάτωση Ανάλυσης Συναισθήματος (Sentiment Analysis):** Χρήση τεχνικών NLP (Natural Language Processing) για την ανάλυση οικονομικών ειδήσεων και αναρτήσεων στα social media, ώστε το μοντέλο να λαμβάνει υπόψη και την ψυχολογία της αγοράς.
2. **Χρήση Transformers:** Μετάβαση από τα επαναλαμβανόμενα δίκτυα (RNN/xLSTM) σε αρχιτεκτονικές Transformer (Attention Mechanism), που επιτρέπουν την παράλληλη επεξεργασία δεδομένων.
3. **Υψηλότερη Συχνότητα Δεδομένων:** Χρήση ημερήσιων ή εβδομαδιαίων δεδομένων για βραχυχρόνιες προβλέψεις (trading), αντί για μεσο-μακροπρόθεσμες επενδυτικές στρατηγικές.

## ΒΙΒΛΙΟΓΡΑΦΙΑ

### Ξενόγλωσση Βιβλιογραφία (References)

1. **Akinniyi, P.** (2023). *Data Governance and Security Frameworks in Cloud-Based Financial Analytics*. *International Journal of Information Management*, 58, 102-115.
2. **Beck, M., Pöppel, K., Spanring, A., et al.** (2024). *xLSTM: Extended Long Short-Term Memory*. arXiv preprint arXiv:2405.04517. (Η βασική δημοσίευση για την αρχιτεκτονική xLSTM/mLSTM).
3. **Hochreiter, S., & Schmidhuber, J.** (1997). *Long Short-Term Memory*. *Neural Computation*, 9(8), 1735–1780. (Η θεμελιώδης δημοσίευση για το LSTM).
4. **Lăzăroi, G., Andronie, M., Iacob, Ş., & Geamănu, M.** (2023). *The Role of Artificial Intelligence in the Financial Sector: Trends, Challenges, and Opportunities*. *Economics, Management, and Financial Markets*, 18(1), 9-25.
5. **Pamisetty, S.** (2022). *Machine Learning Applications in Algorithmic Trading and Risk Management in Cloud Environments*. *Journal of Financial Data Science*, 4(2), 45-58.
6. **Rehan, M.** (2021). *Real-time Fraud Detection in Financial Systems using Deep Learning Architectures*. *IEEE Transactions on Computational Social Systems*, 8(4), 987-996.
7. **Rehan, M.** (2022). *Comparative Analysis of Supervised and Unsupervised Learning Models in Banking*. *Journal of Big Data Analytics*, 9, 12-28.
8. **Samuel, J.** (2023). *Cloud Computing and Predictive Analytics: A Strategic Framework for Financial Institutions*. *Journal of Cloud Computing: Advances, Systems and Applications*, 12(1), 34-49.

### Πηγές Δεδομένων & Διαδικτυακές Αναφορές

9. **Bank of Greece (Τράπεζα της Ελλάδος).** (2024). *Μηνιαίο Στατιστικό Δελτίο: Επιτόκια & Πληθωρισμός*. Ανακτήθηκε από: <https://www.bankofgreece.gr/>
10. **Yahoo Finance.** (2024). *Gold Futures (GC=F) Historical Data*. Ανακτήθηκε μέσω Python Library yfinance από: <https://finance.yahoo.com/quote/GC=F/>
11. **PyTorch Documentation.** (2024). *LSTM and Neural Network Modules*. Ανακτήθηκε από: <https://pytorch.org/docs/stable/nn.html>