

# Βαθιά Μάθηση για Πρόβλεψη Ζήτησης Ηλεκτρικού Φορτίου

Ομιλητές: Καθ. Αναστάσιος Τέφας, Δρ. Μαρία Τζελέπη

[tefas@csd.auth.gr](mailto:tefas@csd.auth.gr), [mtzelepi@csd.auth.gr](mailto:mtzelepi@csd.auth.gr)

This project has received funding under:



ARISTOTLE  
UNIVERSITY  
OF THESSALONIKI



Ευρωπαϊκή Ένωση  
Ευρωπαϊκό Ταμείο  
Περιφερειακής Ανάπτυξης

**ΕΠΑνΕΚ 2014-2020**  
**ΕΠΙΧΕΙΡΗΣΙΑΚΟ ΠΡΟΓΡΑΜΜΑ**  
**ΑΝΤΑΓΩΝΙΣΤΙΚΟΤΗΤΑ**  
**ΕΠΙΧΕΙΡΗΜΑΤΙΚΟΤΗΤΑ**  
**ΚΑΙΝΟΤΟΜΙΑ**



**ΕΣΠΑ**  
**2014-2020**  
ανάπτυξη - εργασία - αλληλεγγύη

# Έργο MALENA

Machine Learning System for Energy Data Analysis and Management



ARISTOTLE  
UNIVERSITY  
OF THESSALONIKI

 Medoid AI



# Αγορά Ενέργειας - Στόχοι Έργου MALENA

1. Συνεχής βραχυπρόθεσμη **πρόβλεψη ωριαίας ζήτησης συνολικού φορτίου** του Παρόχου στο Διασυνδεδεμένο Σύστημα Μεταφοράς
2. Συνεχής βραχυπρόθεσμη **πρόβλεψη ωριαίας παραγωγής συνολικού δυναμικού ΑΠΕ** ηπειρωτικής χώρας
3. **Εξατομικευμένη υπηρεσία ενεργειακής διαχείρισης**, αποτελούμενη από βραχυπρόθεσμη (επόμενης ημέρας/εβδομάδας) και μεσοπρόθεσμη (επόμενου μήνα) πρόβλεψη κατανάλωσης καθώς και συστάσεις βέλτιστης ενεργειακής συμπεριφοράς

# Δεδομένα

- Ιστορικά ωριαία δεδομένα κατανάλωσης φορτίου από τον φορέα ΔΕΗ
- Δεδομένα παραγωγής ΑΠΕ (αιολικά, ...)
- Δεδομένα κατανάλωσης ενέργειας για πελάτες ΜΤ και ΥΤ
- Καιρικά δεδομένα (θερμοκρασία, υγρασία, ...)

# Computational Intelligence and Deep Learning Research Group

## Ongoing Projects

CONTACT US

[cidl.csd.auth.gr](mailto:cidl.csd.auth.gr)

[tefas@csd.auth.gr](mailto:tefas@csd.auth.gr)




# Βαθιά Μάθηση

---



# Βαθιά Μάθηση

- Τα **βαθιά νευρωνικά δίκτυα** προσπαθούν να προσομοιώσουν τη συμπεριφορά του ανθρώπινου εγκεφάλου ώστε να **μάθει** από μεγάλες συλλογές δεδομένων
- Τα βαθιά νευρωνικά δίκτυα είναι νευρωνικά δίκτυα με **πολλαπλά** στρώματα



# Εφαρμογές Βαθιάς Μάθησης

Η **Βαθιά Μάθηση** έχει οδηγήσει σε διάφορα **state-of-the-art** αποτελέσματα στα:


- Μηχανική Όραση
- Αυτοοδηγούμενα Αυτοκίνητα (Self-Driving Cars)
- Επεξεργασία Φυσικής Γλώσσας
- Ρομποτική
- Πρόβλεψη Χρονοσειρών
  - 2017 Web Traffic Time Series Forecasting
  - 2018 Corporación Favorita Grocery Sales Forecasting
  - 2018 M4-Competition






# Multi-Layer Perceptron (MLP)

- Η πιο βασική μορφή νευρωνικού δικτύου




# Convolutional Neural Networks (CNN)

- Χρησιμοποιούν διαμοιρασμό βαρών (weight sharing)
- Ικανότητα εξαγωγής χρήσιμων χαρακτηριστικών από τα σήματα εισόδου (εικόνα, ήχος, χρονοσειρές)



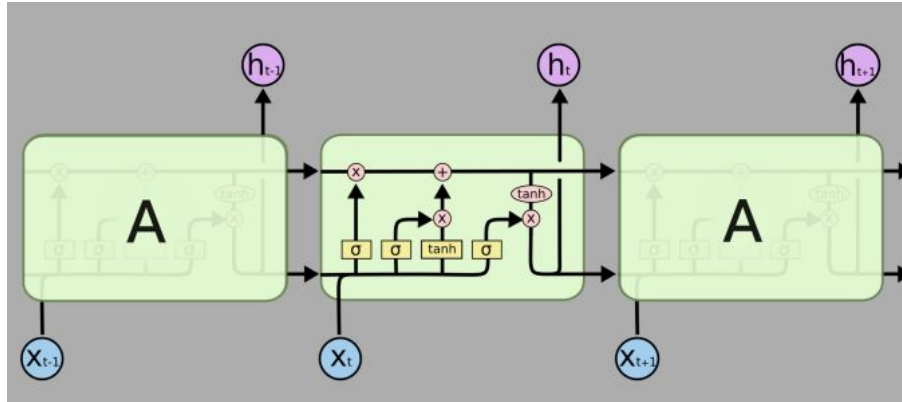
# Recurrent Neural Networks (RNN)

- Εξειδικεύονται στην ανάλυση **χρονοσειρών**
- Ενσωματωμένη **μνήμη** για την ενίσχυση της ικανότητας να θυμούνται παρελθοντικά γεγονότα που έχουν αντίκτυπο στο μέλλον
- Επιρρεπή σε vanishing and exploding gradients




# Long Short Term Memory (LSTM)

- Βελτιώσεις στην αρχιτεκτονική του απλού RNN
- Μια μονάδα LSTM αποτελείται από ένα κελί (cell), μια πύλη εισόδου (input gate), μια πύλη εξόδου (output gate) και μια πύλη forget



# Transformers

- Επεξεργασία Φυσικής Γλώσσας, Μηχανική Όραση, Πρόβλεψη Χρονοσειρών
- Ικανότητα σύλληψης μακροπρόθεσμων εξαρτήσεων (long-range dependencies)



# Εκπαίδευση Νευρωνικών Δικτύων

- Τρία βασικά συστατικά
  - a. Δεδομένα
  - b. Μοντέλο (NN αρχιτεκτονική)
  - c. Συνάρτηση κόστους (Cross Entropy, MSE, Smooth-L1,...)

# Βαθιά Μάθηση για Πρόβλεψη Χρονοσειρών


---



# Πρόβλεψη Χρονοσειρών

- Χρονοσειρές: μια **ιεραρχημένη** ως προς το χρόνο ακολουθία παρατηρήσεων που λαμβάνονται σε τακτά ίσα χρονικά διαστήματα
- Πρόβλεψη χρονοσειρών:

DATE	HOUR	CONSUMPTION
2022-07-12	1	3.074.764
2022-07-12	2	2.965.891
2022-07-12	3	2.890.194
2022-07-12	4	2.841.386
2022-07-12	5	2.863.107
2022-07-12	6	2.909.262
2022-07-12	7	3.258.198
2022-07-12	8	3.644.261
2022-07-12	9	3.873.906
2022-07-12	10	4.093.656





# Επιβλεπόμενη Μάθηση

- Ένα μοντέλο μαθαίνει μια συνάρτηση που αντιστοιχίζει μια είσοδο σε μια έξοδο χρησιμοποιώντας επισημασμένα δεδομένα
- Ορισμός μοντέλου
  - MLP
  - CNN
  - LSTM
- Ορισμός συνάρτησης κόστους
  - Mean Squared Error (MSE)
  - Mean Absolute Percentage Error (MAPE)
  - L1
  - Smooth-L1

# Βαθιά Μάθηση για Πρόβλεψη Χρονοσειρών

- Πρόβλεψη ζήτησης ηλεκτρικού φορτίου για την επόμενη ημέρα (one-day-ahead)
  - Πρόβλεψη **24 τιμών φορτίου**
  - **Regression**
- Βιβλιογραφία: MLPs, CNN, RNN-based, υβριδικά μοντέλα
- Συγκριτική μελέτη state-of-the-art μοντέλων βαθιάς μάθησης
  - “**Βαθείς**” αρχιτεκτονικές & **attention**
- Αξιολόγηση:

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right|$$

Method	Padding	MAPE(%)
1-layered CNN(32)	no padding	13.97
1-layered CNN(32)	causal	16.52
2-layered CNN(32)	no padding	15.12
2-layered CNN(32)	causal	14.87
2-layered CNN(32) + LSTM(16)	no padding	2.11
2-layered CNN(32) + LSTM(16)	causal	2.20
2-layered CNN(32) + GRU(16)	no padding	2.30
2-layered CNN(32) + GRU(16)	causal	2.17
1-layered LSTM(32)	-	2.51
1-layered GRU(32)	-	4.21
1-layered GRU(64)	-	2.19
2-layered LSTM(32, 16)	-	1.99
2-layered GRU(32, 16)	-	1.99
1-layered LSTM(32) + Attention	-	2.15
1-layered GRU(32) + Attention	-	2.30
BiLSTM Seq2Seq	-	2.04
1-layered LSTM Seq2Seq	-	2.34
1-layered GRU Seq2Seq	-	2.28

G. Emmanouilidis, M. Tzelepi and A. Tefas, “Short-Term Electric Load Demand Forecasting on Greek Energy Market using Deep Learning: A comparative study”, PACET 2022

# Προτεινόμενες Μέθοδοι Βαθιάς Μάθησης για Πρόβλεψη Ζήτησης Ηλεκτρικού Φορτίου (ΠΖΗΦ)

---



**Απευθείας Απόσταξη Γνώσης για ΠΖΗΦ**



**Μάθηση υπολειπόμενου σφάλματος για ΠΖΗΦ**



**Μάθηση Κωδικοποιημένης Εισόδου-Εξόδου για ΠΖΗΦ**

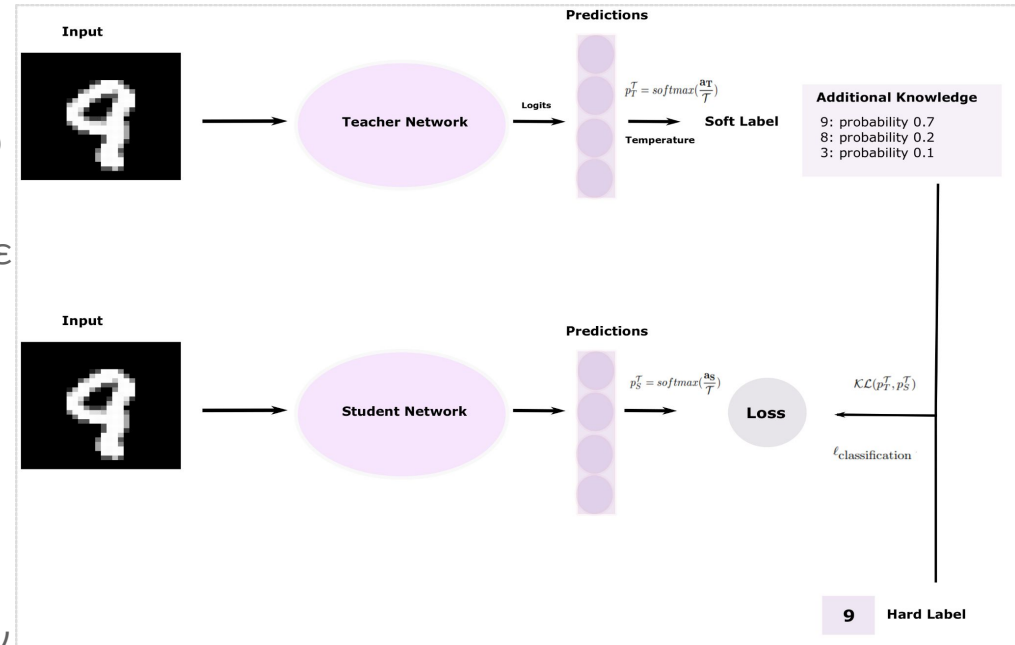
# Απευθείας Απόσταξη Γνώσης για ΠΖΗΦ

---



# Απευθείας Απόσταξη Γνώσης (Online Distillation)

- Εκπαίδευση **αποτελεσματικών ελαφρών** μοντέλων, **μεταφέροντας γνώση** από πιο ισχυρά μοντέλα, μέσω της εξόδου των τελευταίων
  - αποτυπώνεται η **ομοιότητα** κάθε δείγματος με κάθε μια από τις κλάσεις του προβλήματος
- Σύνθετη διαδικασία εκπαίδευσης
- **Απευθείας** απόσταξη γνώσης
- Self-distillation
- **Περιορισμένη εφαρμογή** σε προβλήματα πρόβλεψης χρονοσειρών



# Απευθείας Απόσταξη Γνώσης για ΠΖΗΦ - OSDFn

- **Επεκτείνουμε** την μεθοδολογία της απόσταξης γνώσης σε προβλήματα πρόβλεψης χρονοσειρών
- Αντί να εκπαιδεύουμε το μοντέλο με στόχους τις πραγματικές τιμές φορτίου, προτείνουμε την εκπαίδευση χρησιμοποιώντας τους λεγόμενους **ασαφείς στόχους (soft targets)**
- Ασαφείς στόχοι: συνδυασμός των πραγματικών τιμών φορτίου και των προβλέψεων των πιο **όμοιων** αναπαραστάσεων:  $\mathbf{s}_i = \mathbf{t}_i + \alpha \boldsymbol{\mu}^i$ ,  $\boldsymbol{\mu}^i = \frac{1}{n} \sum_{l=1}^n \Phi(\mathbf{x}_l^i; \mathbf{W})$ 
  - Ευκλείδεια απόσταση
- Συνάρτηση κόστους (MAPE):  $\mathcal{L} = \frac{1}{M} \sum_{i=1}^M \left| \frac{\mathbf{t}_i + \alpha \boldsymbol{\mu}^i - \Phi(\mathbf{x}_i, \mathbf{W})}{\mathbf{t}_i + \alpha \boldsymbol{\mu}^i} \right|$

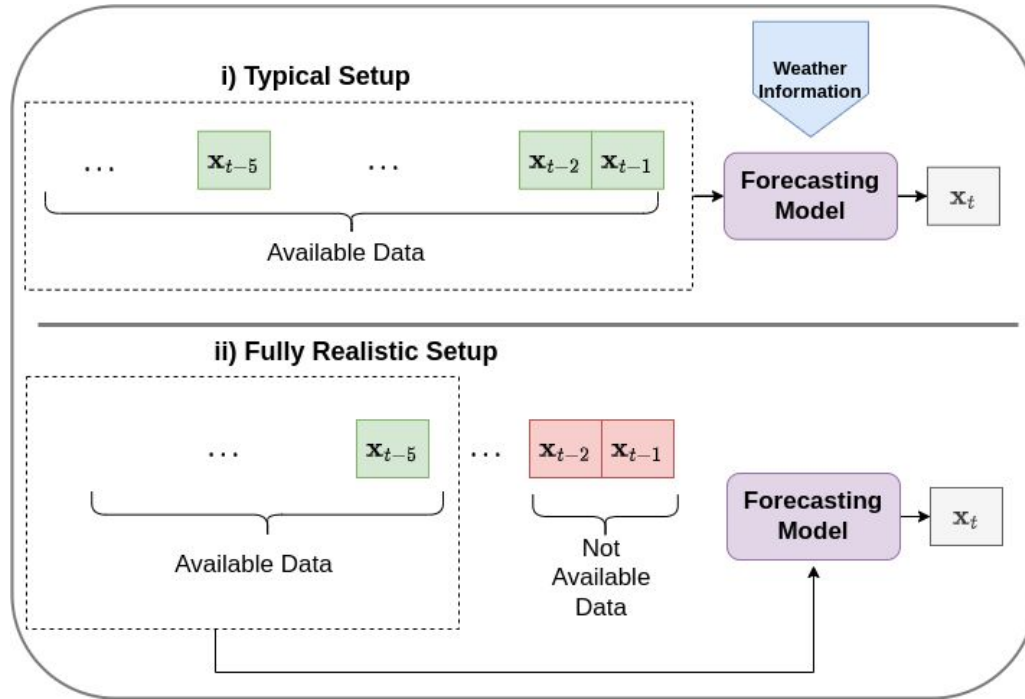
# Μοντέλο - Χαρακτηριστικά Εισόδου

Abbreviation	Dim.	Description
$L_d$	24	Load of the day that is 1 day before TD
$L_w$	24	Load of the day that is 7 days before TD
$L_m$	24	Load of the day that is 28 days before TD
$T_d$	24	Corresponding temperature for $L^d$
$T_w$	24	Corresponding temperature for $L^w$
$T_m$	24	Corresponding temperature for $L^m$
T	24	Corresponding temperature for TD
D	1	Indicator of which day of the week is the TD
W	1	Indicator of TD being weekend
H	1	Indicator of TD being holiday


- 2-layer MLP
- Έξοδος: 24 νευρώνες
- Σχεδιασμός χαρακτηριστικών εισόδου
  - βραχυπρόθεσμα και μακροπρόθεσμα χαρακτηριστικά
  - περιοδικά και “ασυνήθιστα” χρονικά χαρακτηριστικά




# Σενάρια βάσει της διαθεσιμότητας των δεδομένων



# OSDFn - Πειραματικά Αποτελέσματα



Typical Setup



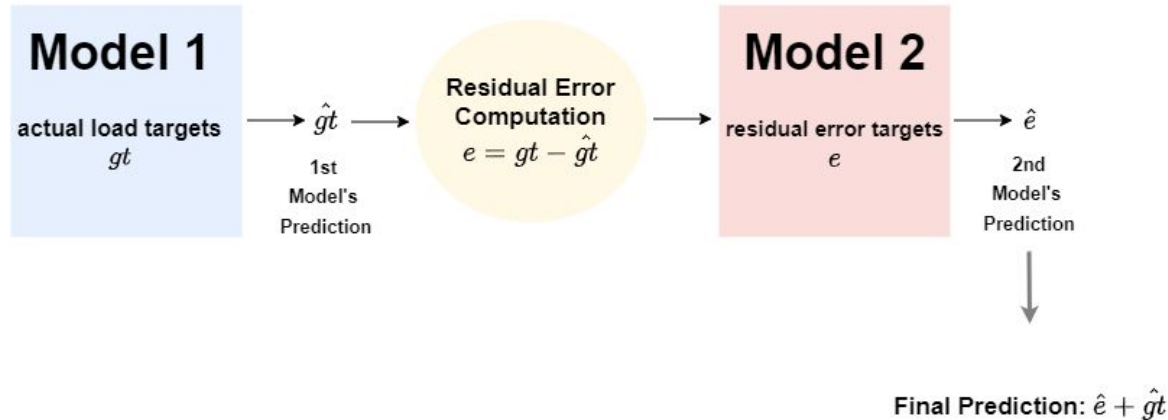
Realistic Setup

M. Tzelepi, A. Sapountzaki, N. Maragkos and A. Tefas, “Online Self-Distillation for Electric Load Demand Forecasting on Greek Energy Market”, PAnhellenic Conference on Electronics and Telecommunications (PACET), 2022

# Μάθηση Υπολειπόμενου Σφάλματος για ΠΖΗΦ

---

# Μάθηση υπολειπόμενου σφάλματος (Residual Error Learning)



- Βελτίωση αν τα σφάλματα είναι συστηματικά

# Residual Error Learning - Πειραματικά Αποτελέσματα

Method	Greece	Spain	ISO-NE
Baseline	$3.36 \pm 0.08$	$5.62 \pm 0.07$	$2.56 \pm 0.15$
Proposed	<b><math>2.63 \pm 0.15</math></b>	<b><math>4.66 \pm 0.14</math></b>	<b><math>2.15 \pm 0.06</math></b>

Table 1: Test MAPE (%) for the proposed method against baseline, where the two models are of identical architecture.

- Εκπαίδευση **ελαφρύτερου** μοντέλου με residual errors
- Επιπλέον βελτίωση

Method	Greece	Spain	ISO-NE
Baseline 1	$3.36 \pm 0.08$	$5.62 \pm 0.07$	$2.56 \pm 0.15$
Baseline 2	$3.39 \pm 0.10$	$6.05 \pm 0.06$	$3.43 \pm 0.30$
Proposed	<b><math>2.52 \pm 0.08</math></b>	<b><math>4.50 \pm 0.08</math></b>	<b><math>1.91 \pm 0.01</math></b>

Table 2: Test MAPE (%) for the proposed method against baseline, where the second model is more lightweight.

# Residual Error Learning - Πειραματικά Αποτελέσματα

- Εφαρμογή στο πρόβλημα της **εξατομικευμένης βραχυπρόθεσμης και μεσοπρόθεσμης πρόβλεψης κατανάλωσης** για καταναλωτές MT και YT
- Πρόβλεψη κατανάλωσης για το **επόμενο έτος σε μηνιαία βάση**

Method	MV	HV
Baseline	8.27	1.66
Proposed	<b>6.19</b>	<b>1.60</b>

Table 1: Test MAPE (%) for the proposed method against baseline for two HV and MV costumers, considering the one-year ahead prediction task.

A. Andronikos, M. Tzelepi and A. Tefas, “Residual Error Learning for Electric Load Demand Forecasting”, to be submitted.


# Μάθηση Κωδικοποιημένης Εισόδου-Εξόδου για ΠΖΗΦ

---




# Μάθηση Κωδικοποιημένης Εισόδου-Εξόδου (Anchored Input-Output Learning)


- Βασίζεται στις **anchored-based** μεθόδους για **ανίχνευση αντικειμένων**
- **Πρόβλεψη offset** σε σχέση με προκαθορισμένα bounding boxes (anchors), αντί για πρόβλεψη απόλυτων συντεταγμένων
  - ευκολότερο για το νευρωνικό να μάθει το offset
- Αναλογικά στο ΠΖΗΦ, μπορούμε να ορίσουμε ένα **anchor** και να **μετασχηματίσουμε** το πρόβλημα σε **πρόβλεψη offset** αντί για απόλυτων πραγματικών τιμών φορτίου



Ground truth image and bounding boxes



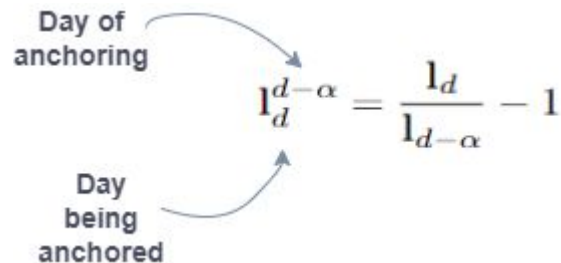
Anchor boxes at each predefined location in each feature map





# AnIO - Anchored Output

- Ως **anchor** ορίζουμε το φορτίο **μια εβδομάδα ή ένα μήνα** πριν την ημέρα πρόβλεψης
- Οι στόχοι κωδικοποιούνται ως η **ποσοστιαία μεταβολή του φορτίου σε σχέση με το φορτίου του anchor** ( $\alpha=\{7,28\}$ ):



$$l_d^{d-\alpha} = \frac{l_d}{l_{d-\alpha}} - 1$$

# AnIO - Anchored Input

- Αντιστοίχως, μπορούμε να **κωδικοποιήσουμε** και την **είσοδο** ώστε να “ταιριάζει” με την κωδικοποιημένη έξοδο
- Κάθε μέρα που χρησιμοποιείται σαν είσοδος **κωδικοποιείται** χρησιμοποιώντας τις αντίστοιχες τιμές μια εβδομάδα νωρίτερα:

$$[l_{d-1}^{d-7}, l_{d-7}^{d-14}, l_{d-28}^{d-35}, t_{d-1}^{d-7}, t_{d-7}^{d-14}, t_{d-28}^{d-35}, w_{\mathbb{I}}]$$

# AnIO - Διαδικασία εκπαίδευσης και αξιολόγησης



## Training Phase

Learning the **percentage change** of the load wrt to the *anchor*


$$\hat{I}_d^{d-\alpha}$$

## Test Phase

The predictions are converted back to the **original load space** so as to be compared with the actual load and evaluate the performance

$$\hat{I}_d = I_{d-\alpha} \cdot (\hat{I}_d^{d-\alpha} + 1)$$


# ΑνΙΟ - Πειραματικά Αποτελέσματα



# AnIO - Πειραματικά Αποτελέσματα

Method	Anchor	Test MAPE (%)
Baseline	-	$2.835 \pm 0.068$
AnO	Week	$2.297 \pm 0.078$
AnO	Month	$2.423 \pm 0.058$
AnIO	Week	<u><math>2.173 \pm 0.054</math></u>
AnIO	Month	<u><math>2.395 \pm 0.024</math></u>

Table 1: Greek Energy Market




M. Tzelepi, P. Nousi and A. Tefas, “Improving Electric Load Demand Forecasting with Anchor-based Forecasting Method”, IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 2023

P. Nousi, M. Tzelepi and A. Tefas, “Anchored Input-Output Learning for Electrical Load Demand Forecasting”, IEEE International Symposium on Circuits and Systems (ISCAS), 2023

# Ongoing Work

- **Informer** για πρόβλεψη χρονοσειρών <sup>1</sup>
- Τεχνικές κανονικοποίησης για βελτίωση ικανότητας πρόβλεψης



<sup>1</sup> Zhou, Haoyi, et al. "Informer: Beyond efficient transformer for long sequence time-series forecasting." *Proceedings of the AAAI conference on artificial intelligence*. Vol. 35. No. 12. 2021.

Ευχαριστούμε για την προσοχή σας

Υλοποιήθηκε στο πλαίσιο της Δράσης ΕΡΕΥΝΩ - ΔΗΜΙΟΥΡΓΩ - ΚΑΙΝΟΤΟΜΩ και συγχρηματοδοτήθηκε από το Ευρωπαϊκό Ταμείο Περιφερειακής Ανάπτυξης (ΕΤΠΑ) της Ευρωπαϊκής Ένωσης και εθνικούς πόρους μέσω του Ε.Π. Ανταγωνιστικότητα, Επιχειρηματικότητα & Καινοτομία (ΕΠΑνΕΚ) (κωδικός έργου: Τ2ΕΔΚ-03048)

