



ΠΑΝΕΠΙΣΤΗΜΙΟ ΠΕΛΟΠΟΝΝΗΣΟΥ

ΣΧΟΛΗ ΜΗΧΑΝΙΚΩΝ

ΤΜΗΜΑ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ

**Πρόγραμμα Μεταπτυχιακών Σπουδών  
«Τεχνολογίες και Υπηρεσίες Ευφύων Συστημάτων  
Πληροφορικής και Επικοινωνιών»**

**Περιγραφή Προτεινόμενης Μεταπτυχιακής Διπλωματικής Εργασίας**

<b>Τίτλος: Few-Shot Learning για Ιατρικές Εικόνες: Εκπαίδευση με Ελάχιστα Δεδομένα</b>		
<b>Επόπτης:</b>	Ταμπακάς Βασίλειος Πιντέλας Μανώλης	<b>e-mail:</b> tampakas@uop.gr
<b>Εκπαιδευτικοί Στόχοι:</b> <ul style="list-style-type: none"><li>Εξοικείωση με τις τεχνικές Few-Shot Learning και την εφαρμογή τους στην ιατρική απεικόνιση.</li><li>Ανάπτυξη και αξιολόγηση meta-learning αλγορίθμων για ταξινόμηση εικόνων με περιορισμένα δεδομένα.</li><li>Χρήση και σύγκριση Prototypical Networks, MAML και άλλων FSL μεθόδων σε ιατρικά datasets.</li><li>Ανάπτυξη πειραματικού πλαισίου για την ανάλυση της γενίκευσης των μοντέλων σε νέες κατηγορίες εικόνων.</li></ul>		
<b>Σύντομη Περιγραφή:</b> <p>Η βαθιά μάθηση (Deep Learning) έχει επιτύχει εξαιρετικές επιδόσεις σε πολλά πεδία, συμπεριλαμβανομένης της ιατρικής απεικόνισης. Ωστόσο, οι περισσότερες μέθοδοι απαιτούν μεγάλα σύνολα δεδομένων για εκπαίδευση, κάτι που δεν είναι πάντα εφικτό, όπως στον ιατρικό τομέα, όπου η συλλογή και η επισήμειωση (annotation/labeling) δεδομένων είναι δαπανηρή και απαιτεί εξειδικευμένο προσωπικό.</p> <p>Το <b>Few-Shot Learning (FSL)</b> είναι μια σύγχρονη τεχνική μάθησης που επιτρέπει σε ένα μοντέλο να <b>γενικεύει και να μαθαίνει νέες κατηγορίες δεδομένων με ελάχιστα δείγματα</b>. Αντί να απαιτεί χιλιάδες παραδείγματα ανά κλάση, το FSL επιχειρεί να αναγνωρίσει μοτίβα με <b>λίγες μόνο εικόνες (1 έως 10 ανά κατηγορία)</b>, χρησιμοποιώντας <b>μετα-μάθηση (meta-learning)</b> και τεχνικές όπως τα <b>Prototypical Networks, Model-Agnostic Meta-Learning (MAML)</b> και <b>Relation Networks</b>.</p> <p>Στην ιατρική διάγνωση, όπου τα δεδομένα είναι <b>περιορισμένα και ανισοκατανεμημένα</b> (π.χ. σπάνιες ασθένειες ή νέες παθήσεις), το Few-Shot Learning μπορεί να:</p> <ul style="list-style-type: none"><li>Επιτρέψει την ταξινόμηση ασθενειών με ελάχιστη εκπαίδευση</li><li>Μειώσει την ανάγκη για μεγάλα ετικετοποιημένα datasets</li><li>Αυξήσει την ικανότητα γενίκευσης σε νέες ιατρικές καταστάσεις</li><li>Συμβάλει στην αυτοματοποίηση της διάγνωσης με περιορισμένους πόρους</li></ul> <p>Αυτή η διπλωματική εργασία θα εστιάσει στην εφαρμογή και αξιολόγηση μεθόδων Few-Shot Learning σε ειδικά ιατρικά datasets, προκειμένου να βελτιωθεί η απόδοση μοντέλων βαθιάς μάθησης ακόμα και σε περιβάλλοντα όπου τα δεδομένα είναι εξαιρετικά περιορισμένα. Θα</p>		

χρησιμοποιηθούν δημόσια διαθέσιμα σύνολα δεδομένων, όπως ISIC (για καρκίνο του δέρματος), CheXpert (για ακτινογραφίες θώρακα) και BraTS (για ανίχνευση όγκων εγκεφάλου).

### Βιβλιογραφία

Finn, C., Abbeel, P., & Levine, S. (2017). Model-Agnostic Meta-Learning for Fast Adaptation of Deep Networks. ICML.

Snell, Jake, Kevin Swersky, and Richard Zemel. "Prototypical networks for few-shot learning." Advances in neural information processing systems 30 (2017).

Pintelas, E., Livieris, I.E. and Pintelas, P., 2024. Adaptive augmentation framework for domain independent few shot learning. Knowledge-Based Systems, 299, p.112047.

Carrión-Ojeda, D., Alam, M., Escalera, S., Farahat, A., Ghosh, D., Diaz, T. G., ... & Yin, X. (2023, August). NeurIPS'22 cross-domain MetaDL challenge: Results and lessons learned. In NeurIPS 2022 Competition Track (pp. 50-72). PMLR.

### Data Sources:

<https://stanfordmlgroup.github.io/competitions/chexpert/>

<https://www.isic-archive.com/>

<https://challenge.isic-archive.com/data/>

<https://www.cancerimagingarchive.net/>

### Η εργασία περιλαμβάνει:

#### 1. Συλλογή και Προεπεξεργασία Δεδομένων

- ο Διαχείριση/συλλογή και δημιουργία μικρών ιατρικών datasets.
- ο Κανονικοποίηση και εξισορρόπηση δεδομένων.
- ο Data Augmentation για ενίσχυση της γενίκευσης.

#### 2. Εφαρμογή Few-Shot Learning Αλγορίθμων

- ο Υλοποίηση και fine-tuning των Prototypical Networks, MAML, και Relation Networks.
- ο Πειραματισμός με Vision Transformers και Knowledge-Augmented Networks (KAN).

#### 3. Αξιολόγηση και Σύγκριση Τεχνικών

- ο Χρήση μετρικών Accuracy, AUC-ROC, F1-Score για σύγκριση απόδοσης.
- ο Ανάλυση robust learning, αντοχή σε θόρυβο και domain shift μεταξύ διαφορετικών datasets.

#### 4. Δημιουργία Framework για Few-Shot Medical Image Learning

- ο Ανάπτυξη pipeline σε **PyTorch** με υποστήριξη για μεταφορά και εφαρμογή σε διαφορετικά datasets.
- ο Ανάπτυξη **νέου μοντέλου** και δοκιμή με **Meta-Dataset framework** για **cross-domain generalization**.

**Προαπαιτούμενα και προϋποθέσεις:** Ικανότητα διαχείρισης, συλλογής και εξόρυξης δεδομένων; Εξοικειωμένος σε Data Mining, Machine/Deep Learning; Αρκετά εξοικειωμένος σε Python και PyTorch programming languages; Ικανότητα εφαρμογής, πειραματισμού και επέκτασης GitHub/Kaggle projects