



קטלוג פרויקטים Data Engineering and AI

פרויקטים לתואר ראשון | שנת הלימודים תשפ"ז | 2026-2027

בחוברת זו תוכלו למצוא את רשימת הפרויקטים הפתוחים לסטודנטים בתוכנית להנדסת נתונים ובינה מלאכותית.

החוברת כוללת:

- את כל הפרויקטים המופיעים בחוברת הפרויקטים הכללית של הנדסת חשמל תחת הרשימות:

Signal Processing
Data Engineering & AI

- פרויקטים נוספים מתוך החוברת הכללית של הנדסת חשמל, המתאימים לסטודנטים בתוכנית.

הקבלה לפרויקט והשיבוץ הסופי מותנים באישור המנחה וראש/ת המעבדה, בהתאם להתאמה ולמקומות הפנויים.

סטודנטים בתוכנית המעוניינים לבחור פרויקט מתוך החוברת הכללית של הנדסת חשמל, שאינו מופיע בחוברת שלפניכם, נדרשים לקבל מראש את אישור ראש התוכנית, פרופ' שרון גנות.

שימו לב: שיוך המסלול/התוכנית המופיע לצד כל פרויקט מתייחס לחלוקה בחוברת הפרויקטים הכללית של הנדסת חשמל בלבד, ואינו מגביל את האפשרות של סטודנטים בתוכנית להנדסת נתונים ובינה מלאכותית להירשם לפרויקטים המופיעים בחוברת שלפניכם.

לפני שנרשמים לפרויקט

מספרי הפרויקטים בפרק זה הם המספרים המקוריים מהטבלה, ולכן אינם בהכרח רציפים.

תהליך הרישום

1. בחירת הפרויקט
2. עברו על החוברת, קראו את דרישות הפרויקט ורשמו את מספר הפרויקט המופיע בפס הצבעוני בראש העמוד.
3. פנייה למנחה ולראש/ת המעבדה
4. צרו קשר באמצעות פרטי ההתקשרות המופיעים בעמוד הפרויקט ובדקו התאמה, זמינות ודרישות מוקדמות.
5. קבלת אישור
6. יש לקבל את אישור המנחה ואת אישור ראש/ת המעבדה לפני השלמת הרישום. רישום ללא אישור אינו מהווה שיבוץ.
7. 4. מילוי טופס הרישום
8. הזינו את הפרטים בדיוק כפי שהם מופיעים בחוברת, ללא קיצורים וללא השמטת שמות.

במעמד הרישום יש להזין בדיוק:

1. מספר הפרויקט - המספר המקורי המופיע בפס הצבעוני בראש עמוד הפרויקט
2. שם הפרויקט - עברית ואנגלית
3. השם המלא של המנחה - כפי שמופיע תחת 'פרטי הנחיה'
4. השם המלא של ראש/ת המעבדה - כפי שמופיע תחת 'פרטי הנחיה'
5. פרטי הסטודנטים - שמות הסטודנטים, (מקסימום 2 לפרויקט), מס' תעודת זהות וכתובת מייל חשוב: מאחר שהחוברת מקובצת לפי מסלולים אך המספרים נשמרו מהטבלה המקורית, ייתכנו דילוגים במספור בתוך כל מסלול. יש להעתיק את המספר המופיע בעמוד הפרויקט עצמו.

לינקים חשובים

אתר הפרויקטים של שנה ד בפקולטה - <https://engineering.biu.ac.il/content/final-projects> + לינקים
בדף
רשימת הפרויקטים בהנדסת חשמל -
<https://engineering.biu.ac.il/sites/engineering/files/shared/Icons/electrical-engineering-track-projects-2026-2027.pdf>
איר נרשמים לפרויקט לאחר אישור מראש המעבדה -
<https://docs.google.com/forms/d/e/1FAIpQLSegtuGNRTLyR5sfHtVmkEsR9YwLFLPry8QSc3XpZBJVayV12A/viewform>

מספר פרויקט: 6 | Signal Processing

הזיות (Hallucinations) במערכת תמלול דיבור (Whisper)
Hallucination Detection for Whisper Automatic Speech Recognition

פרטי הנחיה

שם המנחה המלא: מאיה ויסמן ברנס
דוא"ל המנחה: mayaveismman@gmail.com
ראש/ת המעבדה / אחראי/ת אקדמי/ת: פרופ' שרון גנות
דוא"ל ראש/ת המעבדה: Sharon.Gannot@biu.ac.il

לרישום יש להזין: מספר פרויקט 6 | שם המנחה המלא: לא הוזן שם מנחה בטופס
ראש/ת המעבדה: פרופ' שרון גנות | הקבלה והשיבוץ מותנים באישור שניהם.

רקע לפרויקט

מערכות זיהוי ותמלול דיבור מודרניות הגיעו לרמת דיוק גבוהה מאוד. עם זאת, מחקרים עדכניים הראו כי במצבים מסוימים – למשל ברעש חזק, מקטעי שקט, מוזיקה או אותות שאינם דיבור – המערכת עלולה לייצר תמלול שאינו נתמך על ידי האודיו בפועל. תופעה זו מכונה Hallucination ("הזיות") והיא מהווה אתגר משמעותי ביישומים קריטיים הדורשים אמינות גבוהה. בפרויקט זה יפותח מנגנון אוטומטי לזיהוי מצבי ה"הזיות" בהם מומצא תמלול שגוי. האלגוריתם ינתח במקביל מאפיינים אקוסטיים של האות ומדדי ביטחון פנימיים של מערכת התמלול ותפיק ציון אמינות לכל קטע דיבור.

מטרות הפרויקט

פיתוח מנגנון אוטומטי לזיהוי מצבי ה"הזיות" בהם מומצא תמלול שגוי

נושאים נלמדים

- לימוד והיכרות עם מודלי ASR מודרניים ובפרט Whisper
- בניית סביבת ניסויים לזיהוי "הזיות" בתמלול דיבור
- שילוב מאפיינים אקוסטיים כגון אנרגיה, VAD ויחס אות לרעש
- הערכת ביצועים
- תהליך עבודה מודולרי:
- זיהוי הזיות (שלב א ללא אימון)
- רעש בלבד - שילוב מאפיינים אקוסטיים לזיהוי כגון אנרגיה, VAD

זיהוי הזיות (שלב ב אימון קלסיפייר)

- אות + רעש - אימון קלסיפייר מתוך דיווחי CONFIDENCE ומטא דאטה של המודל עצמו
(Random Forest, Logistic Regression)

זיהוי הזיות (שלב ג אימון טמפורלי)

- עבודה וחילוך token ים של המודל
- אימון רשת על ה sequence בזמן
(רשתות Temporal CNN, LSTM, transformer)

מספר פרויקט: 7 | Signal Processing

שיעור פרמטרי מעגל חשמלי ממדידת

Circuit parameters estimations from measurements

פרטי הנחיה

שם המנחה המלא: פני טנדייטניק

דוא"ל המנחה: pinchas.tandeyt@biu.ac.il

ראש/ת המעבדה / אחראי/ת אקדמי/ת: פרופ' שרון גנות

דוא"ל ראש/ת המעבדה: Sharon.Gannot@biu.ac.il

לרישום יש להזין: מספר פרויקט 7 | שם המנחה המלא: פני טנדייטניק
ראש/ת המעבדה: פרופ' שרון גנות | הקבלה והשיבוץ מותנים באישור שניהם.

רקע לפרויקט

נתונה טופולוגיה של מעגל חשמלי ואנו מעוניינים לשערך את פרמטרי המעגל החשמלי. ממדידות אימפדנס של המעגל החשמלי (בדרך כלל 10 נקודות בדקדה), מתקבל חלק ממשי ומדומה לכל תדר (Nyquist plot). על סמך מדידות אלו אנו נרצה לשערך את פרמטרי המעגל החשמלי. מקור הבעיה הנו DATA מעולם האלקטרוכימיה, השיטה נקראת Electrochemical Impedance Spectroscopy. פרמטרי המעגל החשמלי שאנו משערכים ממופים לתהליכים כימיים אשר קורים בתמיסה. המעגל השקול נקרא [1] Randles circuit. בנוסף תבחן אפשרות ל Circuit system identification בעזרת רשת עיצבית מסוג PINN (Physics-Informed Neural Network) [3] אשר יכולה לשמש לתאור מיגוון מודלים של ODE עם כניסה משתנה בזמן.

Bibliography:

[1] https://en.wikipedia.org/wiki/Randles_circuit

[2] Doonyapisut, D., et al. "Analysis of electrochemical impedance data: use of deep neural networks. Adv Intell Syst 5 (8): 2300085." 2023, <https://advanced.onlinelibrary.wiley.com/doi/full/10.1002/aisy.202300085>

[3] Cuomo, S.; Di Cola, V. S.; Giampaolo, F.; Rozza, G.; Raissi, M.; Piccialli, F. Scientific Machine Learning Through Physics-Informed Neural Networks: Where We Are and What's Next. J. Sci. Comput. 2022, 92 (3), 88. <https://doi.org/10.1007/s10915-022-01939-z>

מטרות הפרויקט

בפרויקט זה הסטודנטים יתנסו במחקר יישומי בתחומי Deep Learning ושיעור פרמטרים של טופולוגיה של מעגל חשמלי ידוע או תאור מודל פיזיקלי בעזרת ODE (ראו דוגמה במאמר [2,3]). כחלק מהתהליך, הסטודנטים יתרגלו סקר ספרות, הבנה וסיכום של מאמרים עכשוויים בתחום

נושאים נלמדים

- הבנה של רשתות deep learning וישומים של רשתות עיצביות ל Multi dimensional regression
- PINN לפיתרון מיגוון בעיות ODE
- סקר ספרות למציאת שיטות לפיתרון הבעיה
- שימוש בפיתרון על מנת לאמן את המודל
- תבחן אפשרות להרחבת המודלים לפתרון בעיות מסוג PDE & FODE

מספר פרויקט: 35 | Signal Processing

חילוץ דובר מטרה בשמע דו אוזני בזמן אמת

Real-time binaural target speaker extraction on HATS

פרטי הנחיה

שם המנחה המלא: יואב אלינסון

דוא"ל המנחה: yoav.ellinson@biu.ac.il

ראש/ת המעבדה / אחראי/ת אקדמי/ת: פרופ' שרון גנות

דוא"ל ראש/ת המעבדה: sharon.gannot@biu.ac.il

לרישום יש להזין: מספר פרויקט 35 | שם המנחה המלא: יואב אלינסון
ראש/ת המעבדה: פרופ' שרון גנות | הקבלה והשיבוץ מותנים באישור שניהם.

רקע לפרויקט

למידה עמוקה ועיבוד ספרתי של אותות

מטרות הפרויקט

הסטודנטים יממשו אלגוריתם שפותח במעבדה לעבודה בזמן אמת על סימולטור HATS- Head and Torso Simulator. כמוכן יבצעו ולידציה לאלגוריתם בסביבות אקוסטיות אמיתיות.

נושאים נלמדים

עיבוד אותות דיבור, שימוש בייצוג זמן תדר לאותו דיבור, למידה עמוקה.

מספר פרויקט: 56 | Signal Processing

ניתוח שכבות פנימיות של מודל אודיו-וידאו באמצעות Linear Probing
A Layer-wise Analysis of Audio-Visual Speech Representations Using Linear Probing

פרטי הנחיה

שם המנחה המלא: מאיה ויסמן ברנס
דוא"ל המנחה: mayaveismman@gmail.com
ראש/ת המעבדה / אחראי/ת אקדמי/ת: פרופ' שרון גנות
דוא"ל ראש/ת המעבדה: Sharon.Gannot@biu.ac.il

לרישום יש להזין: מספר פרויקט 56 | שם המנחה המלא: מאיה ויסמן ברנס
ראש/ת המעבדה: פרופ' שרון גנות | הקבלה והשיבוץ מותנים באישור שניהם.

רקע לפרויקט

מודלים מודרניים לזיהוי דיבור אודיו-ויזואלי (Audio-Visual Speech Recognition – AVSR),
ובראשם AV-HuBERT, מציגים ביצועים מצוינים גם בתנאי רעש קשים. למרות זאת, עדיין לא ברור מה
בדיוק כל שכבה פנימית במודל לומדת.

מטרת הפרויקט היא לבצע ניתוח אינטרפרטבילי של הייצוגים הפנימיים של המודל באמצעות linear
probing ולבחון כיצד המידע הלשוני מיוצג לאורך שכבות המודל וכיצד הייצוג משתנה כאשר איכות
האודיו יורדת.

מטרות הפרויקט

הפרויקט יענה על שלוש שאלות מחקר מרכזיות: 1. באיזו שכבה של מודל אודיו-וידאו ניתן לשחזר
בצורה הטובה ביותר את זהות המילה? 2. כיצד משתנה הייצוג בין אודיו-וידאו יחד, אודיו בלבד, וידאו
בלבד. 3. כיצד רעש משפיע על המידע הקיים בכל שכבה? 4. אילו מילים מפיקות את התועלת הגדולה
ביותר מהמידע הוויזואלי? העבודה מודולרית: בחלק הראשון נבצע הכנת בסיסי הנתונים- ביצוע יישור
וחילוף המילים מהדאטסט, ניקוי, חלוקה לספליטים- train, val, test ובחירת אוצר המילים. חלק שני
נחלץ ייצוגים (אמבדינג) מהמודל אודיו-וידאו. בחלק השלישי נאמן קלסיפייר פשוט על כל שכבה במודל
לניבוי המילה בתוך שכבות המודל. חלק רביעי- ניתוח ביצועים זיהוי המילים בשכבות המודל. ניתוח
רעשים. והצגת תוצרים.

נושאים נלמדים

- היכרות עם מודלים של אודיו-וידאו ומאגרי נתונים לדיבור אודיו-ויזואלי
- עקרונות Self-Supervised Learning וניתוח ייצוגים במודלים עמוקים
- שימוש ב-Linear Probing לניתוח המידע המקודד בשכבות שונות של הרשת
- אימון והערכת מסווגים לינאריים (Logistic Regression)
- עבודה עם Python וספריות מחקר כגון PyTorch, Fairseq ו-Scikit-learn.

מספר פרויקט: 102 | Signal Processing

יצירת מוזיקה מטקסט ביעילות אימון גבוהה באמצעות מודלי מרחב-מצב
Training-Efficient Text-to-Music Generation with State-Space Modeling

פרטי הנחיה

שם המנחה המלא: Mordehay Moradi
דוא"ל המנחה: mordehay2010@gmail.com
ראש/ת המעבדה / אחראי/ת אקדמי/ת: Prof Sharon Gannot
דוא"ל ראש/ת המעבדה: sharon.gannot@biu.ac.il

לרישום יש להזין: מספר פרויקט 102 | שם המנחה המלא: Mordehay Moradi
ראש/ת המעבדה: Prof Sharon Gannot | הקבלה והשיבוץ מותנים באישור שניהם.

רקע לפרויקט

Recent advances in text-to-music (TTM) generation have enabled high-quality music synthesis, but existing approaches often require substantial computational resources and large-scale proprietary datasets. This creates significant barriers to reproducibility and limits the ability to train such models under constrained computational budgets. State-Space Models (SSMs), such as Mamba and SiMBA, provide an efficient alternative to Transformers by enabling linear-complexity sequence modeling. This project explores the use of SSMs as the backbone for text-to-music generation, with a focus on reducing training cost while maintaining competitive generation quality.

מטרות הפרויקט

The primary goal of this project is to develop an open-source and training-efficient text-to-music generation model that can be trained under a constrained computational budget. The project will investigate SSM-based architectures, including Mamba and SiMBA, and compare single-stage generation with a two-stage SSM/diffusion approach for efficient music synthesis. The resulting models will be evaluated against established baselines using objective and subjective measures of audio quality, semantic consistency, and text-audio alignment.

נושאים נלמדים

1. We will base this project on the work presented in the preprint Training-Efficient Text-to-Music Generation with State-Space Modeling by Wei-Jaw Lee, Fang-Chih Hsieh, Xuanjun Chen, Fang-Duo Tsai, and Yi-Hsuan Yang (arXiv:2601.14786, 2026), submitted to IEEE/ACM Transactions on Audio, Speech, and Language Processing (TASLP).
2. Deep Learning Architectures
 - o State-Space Models (SSMs), including Mamba and SiMBA.
 - o Transformers and Attention mechanisms.
 - o Efficient long-range sequence modeling.
3. Generative Models & Audio Processing
 - o Text-to-Music (TTM) generation.
 - o Neural Audio Codecs and Residual Vector Quantization (RVQ).
 - o Latent Diffusion Models (LDMs) and multi-stage generation.
4. Machine Learning Efficiency
 - o Training efficiency and computational complexity.
 - o Parameter reduction and FLOPs optimization.
 - o Training generative models under limited computational resources.
5. Evaluation Metrics
 - o Fréchet Distance (FD) for audio quality.
 - o Kullback-Leibler (KL) divergence for semantic consistency.
 - o CLAP score for text-audio alignment.

מספר פרויקט: 103 | Signal Processing

שחזור טקסט מהקלטות מקלדת בסביבות רועשות (Acoustic Side-Channel Attack) באמצעות שילוב מודלי ראייה (Vision Transformers) ומודלי שפה קטנים (SLMs)
Reconstructing Typed Text from Acoustic Keyboard Recordings in Noisy Environments Using Vision Transformers and Small Language Models

פרטי הנחיה

שם המנחה המלא: Mordehay Moradi
דוא"ל המנחה: mordehay2010@gmail.com
ראש/ת המעבדה / אחראי/ת אקדמי/ת: Prof Sharon Gannot
דוא"ל ראש/ת המעבדה: sharon.gannot@biu.ac.il

לרישום יש להזין: מספר פרויקט 103 | שם המנחה המלא: Mordehay Moradi
ראש/ת המעבדה: Prof Sharon Gannot | הקבלה והשיבוץ מותנים באישור שניהם.

רקע לפרויקט

Acoustic Side-Channel Attacks (ASCAs) exploit unintended acoustic emissions produced during keyboard typing, potentially allowing sensitive information to be inferred from audio recordings. This project investigates how much information about typed text can leak through such acoustic signals under realistic and noisy conditions. While recent deep learning approaches use Mel-spectrograms and neural networks to classify keystrokes, their performance can degrade significantly in the presence of background noise. The project will explore Vision Transformers for robust acoustic feature extraction and Small Language Models (SLMs) for contextual correction of noisy predictions, providing a practical assessment of the extent of information leakage and helping identify potential directions for protecting sensitive information.

מטרות הפרויקט

The primary goal of this project is to quantify the extent to which typed text can be reconstructed from acoustic keyboard recordings under realistic noisy conditions. The system will combine STFT-based keystroke segmentation, Mel-spectrogram representations, and a Vision Transformer for acoustic character classification, followed by an SLM for contextual correction of noisy predictions. The results will be used to assess the practical severity of acoustic information leakage and identify potential measures for mitigating this privacy risk.

נושאים נלמדים

The project will be based on the methodologies and findings presented in the following research papers:

- Julia Przybytniowska, Adam Zychowski, and Jacek Mandziuk, "Deep Learning for Acoustic Side-Channel Attacks on Keyboards: Sterile vs. Noisy Environments," in Proceedings of the 2026 International Joint Conference on Neural Networks (IJCNN 2026), 2026 — focusing on robust keystroke recognition using modern vision architectures such as CoAtNet, MOAT, and Swin Transformer, with particular emphasis on generalization to realistic noisy environments.
- Seyyed Ali Ayati, Jin Hyun Park, Yichen Cai, and Marcus Botacin, "Making Acoustic Side-Channel Attacks on Noisy Keyboards Viable with LLM-Assisted Spectrograms' "Typo" Correction," in Proceedings of the 19th USENIX WOOT Conference on Offensive Technologies (WOOT '25), 2025 — focusing on robust keystroke classification and the use of Large/Small Language Models for correcting acoustically induced classification errors and improving text reconstruction in noisy conditions.

1. Side-Channel Attacks & Information Security:
 - Acoustic Side-Channel Attacks (ASCA).
2. Audio & Signal Processing:
 - Fast Fourier Transform (FFT) & Short-Time Fourier Transform (STFT).
 - Mel-Spectrograms.
 - Energy-based Segmentation.
 - Data Augmentation (Time stretching, Time shifting, Gaussian noise, Frequency/Time masking).
3. Deep Learning & Computer Vision:
 - Convolutional Neural Networks (CNN).
 - Vision Transformers (Swin, ViT, BEiT, DeiT).
 - Hybrid Architectures (CoAtNet, MOAT).
 - Optimization Algorithms & Loss Functions (Adam, AdamW, Cross-Entropy Loss).
4. Large Language Models (LLMs) & Natural Language Processing (NLP):
 - Error Correction / Denoising (Typo correction).
 - Prompt Engineering (Few-shot prompting, Zero-shot prompting).
 - Fine-tuning & Parameter-Efficient Fine-Tuning (PEFT, LoRA, QLoRA).
 - Text Evaluation Metrics (Levenshtein Distance, BLEU, ROUGE, METEOR).

מספר פרויקט: 109 | Signal Processing

גילוי רחפנים אקוסטי בזמן אמת בשיטות למידה עמוקה

Acoustic detection of attacking drone using DL methods

פרטי הנחיה

שם המנחה המלא: ד"ר עופר שוורץ ודניאל לוי

דוא"ל המנחה: oferico.sh@gmail.com

ראש/ת המעבדה / אחראי/ת אקדמי/ת: שרון גנות

דוא"ל ראש/ת המעבדה: Sharon.Gannot@biu.ac.il

לרישום יש להזין: מספר פרויקט 109 | שם המנחה המלא: ד"ר עופר שוורץ ודניאל לוי
ראש/ת המעבדה: שרון גנות | הקבלה והשיבוץ מותנים באישור שניהם.

רקע לפרויקט

בשנים האחרונות הפך השימוש ברחפנים אזרחיים וצבאיים לנפוץ ונגיש מאי פעם. לצד היתרונות הרבים, תופעה זו יצרה איומים ביטחוניים וביטחוניים חדשים, כאשר רחפנים עוינים (רחפנים תוקפים) משמשים למטרות ריגול, פגיעה בפרטיות, הברחות ואף נשיאת חומרי נפץ. שיטות ההגנה המסורתיות, כגון שימוש במכ"מים קרקעיים או שיבוש תדרים, מוגבלות לרוב בגלל תוואי שטח מורכב, מכשולים עירוניים או פגיעה בתקשורת אזרחית תמימה. כמענה לכך, התפתח הצורך במערכות הגנה דינמיות, המזהות רחפנים באופן אוטונומי.

מטרות הפרויקט

מטרתו המרכזית של פרויקט זה היא לתכנן, לפתח וליישם מערכת אוטונומית, המיועדת לגילוי בזמן אמת אחר רחפן תוקף. המערכת שואפת לשלב אלגוריתמים מתקדמים של עיבוד אות שמע ולמידת מכונה כדי לאתר את המטרה העוינת מתוך קלט מקרופונים כל זאת תוך התמודדות עם תנאי סביבה משתנים, הפרעות ושינויי כיוון פתאומיים של המטרה. פיתוח זה מהווה תשתית חיונית למערכות יירוט ונטרול עתידיות של רחפנים עוינים.

נושאים נלמדים

שיטות למידה עמוקה לזיהוי אות שמע של רחפן : שימוש בטכניקות עיבוד אות ורשתות נוירונים (AST, PANN , BEATS) לצורך גילוי של רחפנים במרחב.
לצורך הפרויקט יעמדו לרשות הסטודנטים המערכת אשר פותחה לצורך סיירת עיבוד אותות במסגרת קורב אותות ומערכות.
מאמרים תומכים:

Seidaliyeva, Ulzhalgas, et al. "Advances and Challenges in Drone Detection and Classification Techniques: A State-of-the-Art Review." Sensors (14248220) 24.1 (2024).

מספר פרויקט: 100 | Signal Processing

מעקב אחר רחפן תוקף על ידי רחפן מגן

Tracking of an attacking drone by a defensive drone

פרטי הנחיה

שם המנחה המלא: ד"ר עופר שוורץ ודניאל לוי

דוא"ל המנחה: Oferico.sh@gmail.com

ראש/ת המעבדה / אחראי/ת אקדמי/ת: שרון גנות

דוא"ל ראש/ת המעבדה: Sharon.Gannot@biu.ac.il

לרישום יש להזין: מספר פרויקט 100 | שם המנחה המלא: ד"ר עופר שוורץ ודניאל לוי
ראש/ת המעבדה: שרון גנות | הקבלה והשיבוץ מותנים באישור שניהם.

רקע לפרויקט

בשנים האחרונות הפך השימוש ברחפנים אזרחיים וצבאיים לנפוץ ונגיש מאי פעם. לצד היתרונות הרבים, תופעה זו יצרה איומים ביטחוניים ובטיחותיים חדשים, כאשר רחפנים עוינים (רחפנים תוקפים) משמשים למטרות ריגול, פגיעה בפרטיות, הברחות ואף נשיאת חומרי נפץ. שיטות ההגנה המסורתיות, כגון שימוש במכ"מים קרקעיים או שיבוש תדרים, מוגבלות לרוב בגלל תוואי שטח מורכב, מכשולים עירוניים או פגיעה בתקשורת אזרחית תמימה. כמענה לכך, התפתח הצורך במערכות הגנה דינמיות ואוטונומיות, המבוססות על רחפנים מגנים. רחפן מגן מספק פתרון נייד וגמיש, המסוגל לפעול בגובה רב, להתגבר על חסמים קרקעיים ולסגור את הטווח אל מול האיום בצורה ממוקדת ויעילה.

מטרות הפרויקט

מטרתו המרכזית של פרויקט זה היא לתכנן, לפתח וליישם מערכת אוטונומית לרחפן מגן, המיועדת לגילוי, זיהוי ומעקב בזמן אמת אחר רחפן תוקף. המערכת שואפת לשלב אלגוריתמים מתקדמים של עיבוד אות שמע ולמידת מכונה כדי לאתר את המטרה העוינת מתוך קלט מקרופונים הממוקמים על הרחפן המגן. עם גילוי האיום, הרחפן המגן נדרש לחשב את מסלול הטיסה האופטימלי כדי לעקוב אחר הרחפן התוקף ולשמור עמו על קשר-שמע רציף, כל זאת תוך התמודדות עם תנאי סביבה משתנים, הפרעות ושינויי כיוון פתאומיים של המטרה. פיתוח זה מהווה תשתית חיונית למערכות יירוט ונטרול עתידיות של רחפנים עוינים. בנוסף יש לתכנן מערכת לביטול הרעש העצמי של הרחפן המגן.

נושאים נלמדים

אלגוריתמי מעקב אחר רחפנים: יישום אלגוריתמים עמוקים (YOLO, MAMBA) למעקב רציף אחר רחפן נע תוך כדי תנועה של הרחפן המגן כדי להעריך את מיקום הרחפן התוקף גם במצבים רועשים. לצורך הפרויקט יעמדו לרשות הסטודנטים המערכת אשר פותחה לצורך סיירת עיבוד אותות במסגרת קורב אותות ומערכות.

Chang, Xianyu, et al. "A surveillance system for drone localization and tracking using acoustic arrays." 2018 IEEE 10th Sensor Array and Multichannel Signal Processing Workshop (SAM). IEEE, 2018.

מספר פרויקט: ווו | Signal Processing

איכון מקור קול באמצעות רשת נוירונים מונחת-פיזיקה

Acoustic Source Localization Using Inverse Physics-Informed Neural Networks

פרטי הנחיה

שם המנחה המלא: אביעד אוסטר

דוא"ל המנחה: aviad.oster@gmail.com

ראש/ת המעבדה / אחראי/ת אקדמי/ת: פרופ' שרון גנות

דוא"ל ראש/ת המעבדה: gannotsh@gmail.com

לרישום יש להזין: מספר פרויקט ווו | שם המנחה המלא: אביעד אוסטר
ראש/ת המעבדה: פרופ' שרון גנות | הקבלה והשיבוץ מותנים באישור שניהם.

רקע לפרויקט

איכון מקור קול מתוך מדידות של מערך מיקרופונים הוא רכיב חשוב במערכות רבות. בחדרים סגורים, החזרים מהקירות, רעש רקע ומספר מוגבל של מיקרופונים מקשים על שיטות איכון קלאסיות ופוגעים בדיוק האיכון. רשתות נוירונים מונחות-פיזיקה (PINNs) הן רשתות אשר מעבר להתאמה לנתונים, משלבות בתהליך האימון גם את המשוואות הפיזיקליות המתארות את המערכת. כך ניתן להשתמש בידע מוקדם על התפשטות גלי קול כדי לייצב את הפתרון גם כאשר מספר המדידות קטן או כשהן רועשות. בפרויקט זה יפותח מודל Inverse PINN אשר יקבל מדידות לחץ אקוסטי ממספר מיקרופונים וישערך את מיקום מקור הקול ואת עוצמתו, תוך דרישה ששדה הלחץ המשוחזר יקיים את משוואת הלמהולץ ואת תנאי השפה של החדר.

מטרות הפרויקט

מטרת הפרויקט היא לפתח ולבחון שיטה לאיכון מקור קול יחיד בחדר בעל גאומטריה ידועה. המודל יקבל מדידות לחץ ממספר מיקרופונים וישערך: • את מיקום מקור הקול • את עוצמת המקור (תוצר לוואי) • את שדה הלחץ האקוסטי בחדר (תוצר לוואי) איכון המקור הוא המטרה המרכזית של הרשת בעוד השדה האקוסטי הינו תוצר לוואי. ביצועי השיטה יושוו לאלגוריתם איכון קלאסי ולמודל למידה שאינו כולל אילוצ פיזיקלי. מקורות: • Gu, C., & Chen, Z. (2025). "Integrating Distributed Acoustic Sensing and PINN Frameworks for Enhanced Indoor Sound Source Localization." International Conference on Learning Representations (ICLR). • Raissi, M, Perdikaris, P., & Karniadakis, G. E. (2019). "Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations." Journal of Computational Physics, 378, 686-707

נושאים נלמדים

- רקע באקוסטיקה, משוואת הלמהולץ ושיטות לאיכון מקורות קול.
- היכרות עם PINNs ועם פתרון בעיות הפוכות באמצעות רשתות נוירונים.
- בניית סימולציה של חדר דו-ממדי, מקור קול ומערך מיקרופונים.
- מימוש אלגוריתם איכון בסיסי לצורך השוואה.
- פיתוח ואימון מודל Inverse PINN לשערוך מיקום ועוצמת המקור.
- בחינת הביצועים כתלות במספר המיקרופונים, פריסתם, התדר ורמת הרעש.

מספר פרויקט: 110 | Signal Processing

אינטרפולציה של תגובות אימפולס בינאורליות בחדר באמצעות רשתות נוירונים מונחות-פיזיקה
Binaural Room Impulse Response Interpolation Using Physics-Informed Neural Networks

פרטי הנחיה

שם המנחה המלא: אביעד אוסטר
דוא"ל המנחה: aviad.oster@gmail.com
ראש/ת המעבדה / אחראי/ת אקדמי/ת: פרופ' שרון גנות
דוא"ל ראש/ת המעבדה: gannotsh@gmail.com

לרישום יש להזין: מספר פרויקט 110 | שם המנחה המלא: אביעד אוסטר
ראש/ת המעבדה: פרופ' שרון גנות | הקבלה והשיבוץ מותנים באישור שניהם.

רקע לפרויקט

תגובות אימפולס בינאורליות בחדר (BRIR) מתארות את מעבר הקול מן המקור אל שתי אוזני המאזין, ומשלבות את השפעות החדר, הראש והאפרכסות. ביישומים דינמיים, כגון שמע מרחבי ומציאות מדומה, נדרשות תגובות אלו עבור מספר רב של מיקומי מאזין. עם זאת, מדידה ישירה של BRIR בכל נקודה היא תהליך מורכב, ממושך ויקר.

רשתות נוירונים מונחות-פיזיקה (PINNs) משלבות בתהליך האימון הן התאמה לנתונים הנמדדים והן אילוצים הנגזרים מן המשוואות הפיזיקליות המתארות את המערכת. שילוב זה מאפשר לנצל ידע מוקדם על התפשטות גלי קול, ובכך לשפר את יציבות השחזור גם כאשר מספר המדידות מצומצם או כאשר המדידות מכילות רעש.

במאמר שעליו מבוסס הפרויקט מוצעת רשת נוירונים המייצגת את ה-BRIR כפונקציה רציפה של הזמן והמיקום במרחב. הרשת מאומנת באמצעות שילוב של התאמה למדידות ואילוץ המבוסס על משוואת הגלים, במטרה לשחזר תגובות BRIR במיקומים שבהם לא בוצעה מדידה ישירה.

מטרות הפרויקט

מימוש ובחינה של שיטה מבוססת PINN לאינטרפולציה של BRIR מתוך מדידות במספר מצומצם של מיקומים בחדר. ביצועי המודל ישוו לרשת ללא אילוץ פיזיקלי ולשיטת אינטרפולציה קלאסית. בנוסף תיבחן השפעת מספר נקודות המדידה ורמת הרעש על איכות השחזור. 1. Y. Li, L. Wang and J. Reiss, "Binaural Room Impulse Responses Interpolation Using Physics-Informed Neural Networks in Three Dimensions." 2. X. Karakonstantis, D. Caviedes-Nozal, A. Richard and E. Fernandez-Grande, "Room Impulse Response Reconstruction with Physics-Informed Deep Learning," Journal of the Acoustical Society of America, 2024
<https://github.com/xefonon/RIRPINN>

נושאים נלמדים

- עקרונות של HRTF ו-RIR.
- הבנה של רשתות SIREN ו-Implicit Neural Representation.
- שימוש במאגר סינתטי של תגובות BRIR עבור מיקומי מאזין שונים בחדר.
- מימוש רשת המקבלת זמן ומיקום ומחזירה את ערך תגובת האימפולס.
- שילוב איבר הפסד המבוסס על משוואת הגלים.
- השוואה בין רשתות SIREN עם ובלי אילוץ פיזיקלי ואינטרפולציה רגילה.
- בחינת השפעת דלילות המדידות ורעש על ביצועי המערכת.

מספר פרויקט: 122 | Signal Processing

פענוח קשב בין שני דוברים באמצעות Pre-Training על על אותות EEG מדובר יחיד
Data-Efficient Auditory Attention Decoding Through Single-Talker EEG Pretraining

פרטי הנחיה

שם המנחה המלא: Yosef Shimon Sella

דוא"ל המנחה: yossisellas@gmail.com

ראש/ת המעבדה / אחראי/ת אקדמי/ת: פרופ' שרון גנות

דוא"ל ראש/ת המעבדה: sharon.gannot@biu.ac.il

לרישום יש להזין: מספר פרויקט 122 | שם המנחה המלא: Yosef Shimon Sella

ראש/ת המעבדה: פרופ' שרון גנות | הקבלה והשיבוץ מותנים באישור שניהם.

רקע לפרויקט

דאטהסטים של מידע EEG של דובר יחיד גדולים הרבה יותר מדאטהסטים של שני דוברים עבור בעיות AAD (Auditory Attention Decoding), אבל לרוב אינם מנוצלים עבור אימון של מפענחי קשב (Attention Decoders).

במאמר המצורף, Thorton et al. פרסמו ארכיטקטורה של match-mismatch שלומדת התאמה בין אותות EEG לדיבור ויכולה לעבור למשימת קשב (Transfer learning).

התאמה של הארכיטקטורה לדאטהסטים קיימים (כמו DTU, KUL), montage harmonization, ו- fine tuning באמצעות מידע AAD מוגבל הן המשימות העיקריות של הפרויקט.

מטרות הפרויקט

הפרויקט יבחן אם מודל שמאומן כבר על דאטהסט EEG רחב של דובר יחיד מקטין את הצורך בדאטהסט של שני דוברים שנדרש במשימות של AAD. תחת אותה בדיקה יושוו שלושה מצבים: 1. Zero – Shot Transfer: העברה ללא אימון נוסף. 2. Fine Tuning: על אחוז מסויים מדאטהסט קיים של שני דוברים. 3. אימון מלא מאפס על אותם אחוזים. הפרויקט יתן עקומת יעילות של דאטה על כמויות מידע לאימון ואורכי חלונות החלטה, עם אופציה לבדיקה של הכללה לדאטהסט נוסף, עם בדיקה של מעבר (Transfer) בין שפות, מונטאז', ומערך הבדיקה.

נושאים נלמדים

Transfer learning; pre-training and fine-tuning; match-mismatch learning; one-dimensional convolutional networks; EEG montage harmonization; speech-envelope processing; data-efficiency experiments; cross-subject evaluation; cross-dataset generalization.

מספר פרויקט: 123 | Signal Processing

האם מתאם גבוה יותר מוביל לפענוח קשב טוב יותר? Deep CCA ו-DMCCA
Does Better Correlation Produce Better Attention Decoding? Deep and Multiway CCA for Two-Talker AAD

פרטי הנחיה

שם המנחה המלא: יוסף שמעון סלע
דוא"ל המנחה: yossisellas@gmail.com
ראש/ת המעבדה / אחראי/ת אקדמי/ת: פרופ' שרון גנות
דוא"ל ראש/ת המעבדה: sharon.gannot@biu.ac.il

לרישום יש להזין: מספר פרויקט 123 | שם המנחה המלא: יוסף שמעון סלע
ראש/ת המעבדה: פרופ' שרון גנות | הקבלה והשיבוץ מותנים באישור שניהם.

רקע לפרויקט

CCA (Canonical Correlation Analysis) לומד ייצוגים של אותות EEG ואותות דיבור עם קורלציה גבוהה כאשר שיטות עמוקות ושיטות רבות-נבדקים כמו DCCA ו-DMCCA (Deep / Multiway CCA) משפרות קורלציה על דאטהסטים של דובר יחיד. שיטות קיימות ממומשות על דובר יחיד, אך עדיין צריך לבדוק עם קורלציה גבוהה בין אותות EEG ודיבור מתורגמת לבחירה טובה יותר של הדובר אליו מקשיבים במשימות של שני דוברים, במיוחד עבור חלונות זמן קצרים ודוברים שלא נשמעו קודם לכן.

מטרות הפרויקט

הסטודנטים יפיקו קודם שחזור של תוצאות המאמר עבור הקורלציות, יתאימו את ההכנה של המידע (pre-processing) והמודלים למונטאז' של דאטהסט של שני דוברים (KUL, DTU), ויגדירו כלל החלטה שישווה את ההטלה (projection) של המידע מה-EEG (הייצוג של המידע) לשני הדוברים המתחרים. השיטות שיבחנו הם: Linear CCA, DCAA, MCCA, DMCCA הן יבחנו תחת ניסויים שונים שבלתי תלויים בנבדקים (cross-trial, subject-independent splitting) ועבור אורכי חלונות החלטה שונים. הפרוייקט יבדוק אם שיפור בקורלציה, עוצמת אפקט (effect size), והתאמה בין נבדקים (inter-subject alignment) מובילים לשיפור בדיוק הפענוח של הקשב (AAD accuracy).

נושאים נלמדים

CCA, DCCA, MCCA, and DMCCA; whitening and SVD; multimodal representation learning; PCA and filter-bank preprocessing; correlation-based loss functions; inter-subject alignment; statistical evaluation; and auditory attention decoding (AAD).

מספר פרויקט: 24 | Data Engineering and AI

אפטום מערכת מודעת זיכרון למודלי שפה

Memory-Aware Native Attention for Reduced KV-Cache Inference

פרטי הנחיה

שם המנחה המלא: Zuher Jahshan

דוא"ל המנחה: zuher1710@gmail.com

ראש/ת המעבדה / אחראי/ת אקדמי/ת: Leonid Yavits

דוא"ל ראש/ת המעבדה: leonid.yavits@biu.ac.il

לרישום יש להזין: מספר פרויקט 24 | שם המנחה המלא: Zuher Jahshan
ראש/ת המעבדה: Leonid Yavits | הקבלה והשיבוץ מותנים באישור שניהם.

רקע לפרויקט

The KV cache has become the dominant memory bottleneck in large language model inference. As context windows extend into the hundreds of thousands of tokens, storing key-value pairs for every historical token in GPU high-bandwidth memory (HBM) becomes prohibitively expensive, limiting batch sizes, throughput, and the practical deployment of long-context models. Recent work has attacked this problem from several directions: trainable sparse attention mechanisms such as Native Sparse Attention (NSA) and DeepSeek's token-granularity lightning indexer reduce the number of keys attended to per query; multi-precision quantization (FP8/FP4) shrinks the per-token footprint; and offloading frameworks such as NOSA relocate cache blocks to CPU DRAM under constrained transfer budgets. However, these approaches largely optimize in isolation — sparsity, precision, and memory placement are rarely co-designed, and the interaction between selection granularity (token vs. block) and offloading efficiency remains poorly characterized.

מטרות הפרויקט

To design, implement, and evaluate a unified KV-cache management framework that jointly optimizes attention sparsity, cache precision, and memory-tier placement for long-context LLM inference. Concretely, the project aims to (1) characterize the accuracy–throughput trade-offs of token-level versus block-level key selection under realistic HBM budgets; (2) develop a natively trainable sparse attention variant whose selection pattern is co-designed with CPU–GPU offloading constraints; and (3) demonstrate measurable improvements in decoding throughput and memory footprint at matched task quality against strong baselines (full attention, NSA, NOSA) on long-context benchmarks.

נושאים נלמדים

Learned sparse selection, Offloading-aware selection policy, Knowledge outcomes

מספר פרויקט: 25 | Data Engineering and AI

בניית עומק חשיבה גנרליזבילי במודלי מחשבה

Adaptive Recursive Depth in Looped Reasoning Models

פרטי הנחיה

שם המנחה המלא: Zuher Jahshan

דוא"ל המנחה: zuher170@gmail.com

ראש/ת המעבדה / אחראי/ת אקדמי/ת: Leonid Yavits

דוא"ל ראש/ת המעבדה: leonid.yavits@biu.ac.il

לרישום יש להזין: מספר פרויקט 25 | שם המנחה המלא: Zuher Jahshan

ראש/ת המעבדה: Leonid Yavits | הקבלה והשיבוץ מותנים באישור שניהם.

רקע לפרויקט

Parameter sharing through recurrence has re-emerged as a promising path toward compute-efficient reasoning models. Architectures such as Ouro and Mixture-of-Recursions (MoR) apply the same transformer blocks iteratively, allowing a model to "think longer" in latent space without growing its parameter count, and to allocate variable depth per token via learned routers. Yet fundamental design questions remain unresolved. Fully backpropagating through unrolled recurrent steps — as Ouro does — causes training instability, requiring conservative learning rates, sandwich normalization, and hard caps on recurrence depth; alternatives that use stop-gradient (as in HRM/TRM-style models) trade this stability for a biased training signal. Similarly, routing mechanisms that decide per-token recursion depth involve non-differentiable top-k selections whose gradient handling varies across implementations and is often under-documented. There is currently no systematic understanding of how gradient-flow strategy, routing design, and recursion depth interact to determine model quality and training stability.

מטרות הפרויקט

To systematically study and improve the training dynamics of looped/recursive reasoning models. The project aims to (1) empirically compare gradient-flow regimes in the recurrence (full backpropagation, truncated, and stop-gradient variants) under controlled settings, quantifying their effects on stability, convergence speed, and downstream quality; (2) design a routing mechanism for adaptive per-token recursion depth that is stable to train and calibrated at inference time; and (3) deliver a trained proof-of-concept model demonstrating that adaptive recursion matches or exceeds a parameter-matched feedforward baseline at lower inference FLOPs.

נושאים נלמדים

Shared recurrent block, Depth router, Gradient-flow strategy as a studied variable (e.g., SOT), Knowledge outcomes

מספר פרויקט: 32 | Data Engineering and AI

חקר השימוש ברשת נוירונים מבוסס פולסים לאפליקציות שונות

System level research into the usage of a Spiking Neural network for complex computing applications

פרטי הנחיה

שם המנחה המלא: Neil Feldman

דוא"ל המנחה: neil.d.feldman@gmail.com

ראש/ת המעבדה / אחראי/ת אקדמי/ת: Joseph Shor

דוא"ל ראש/ת המעבדה: Joseph.Shor@biu.ac.il

לרישום יש להזין: מספר פרויקט 32 | שם המנחה המלא: Neil Feldman
ראש/ת המעבדה: Joseph Shor | הקבלה והשיבוץ מותנים באישור שניהם.

רקע לפרויקט

In recent years Artificial Neural Networks (ANN) have reached maturity, and AI is becoming a technology used everywhere. ChatGPT, Bard and Bing have vast distribution and ANN farms are growing exponentially. The ANN attempts to mimic the human brain as closely as possible to achieve the best possible computing power. As the brain signals are analog and spikey by nature the next step for Artificial Neural Networks is to implement Analog Spiking Neural networks (SNN). The aim of this project is to take a given implementation of a SNN network and use it to develop a solution for different applications such as EEG, GEOPHONE, gesture recognition, frequency analysis etc...

מטרות הפרויקט

In this project you will use python and spiking-jelly platforms to utilize an implementation of a spiking neural network (SNN) and research the advantages of using this network for various applications such as EEG, GEOPHONE, gesture recognition and others. You will develop the code for these applications and demonstrate key advantages of using this implementation with our state-of-the-art SNN network vs. other SNN and ANN implementations. You will compare key performance metrics such as power-per-inference, classification accuracy, network size etc.. and show that this implementation has key advantages.

נושאים נלמדים

In this project the student will be exposed to the spiking jelly code used for MNIST classification using our SNN design and based on this code will implement other applications.

The student will also research possible key use-cases that take advantage of unused features inside the SNN such as VThreshold and refractory time training and look for ways to utilize these features in new applications, for example frequency analysis.

מספר פרויקט: 71 | Data Engineering and AI

למידה עמוקה במימד הזמן

Deep learning in the temporal domain

פרטי הנחיה

שם המנחה המלא: יובל תמיר

דוא"ל המנחה: yuvaltamir23@gmail.com

ראש/ת המעבדה / אחראי/ת אקדמי/ת: מוטי פרידמן

דוא"ל ראש/ת המעבדה: moti43@gmail.com

לרישום יש להזין: מספר פרויקט 71 | שם המנחה המלא: יובל תמיר
ראש/ת המעבדה: מוטי פרידמן | הקבלה והשיבוץ מותנים באישור שניהם.

רקע לפרויקט

מערכות אופטיות מהירות מייצרות כמויות גדולות של מידע התלוי בזמן, כגון סדרות של פולסים, אותות ספקטרליים, מדידות של תהליכים לא-ליניאריים ודינמיקה של לייזרים. במקרים רבים קשה לחלץ מהמדידות את הפרמטרים הפיזיקליים הרלוונטיים באמצעות שיטות אנליטיות רגילות. בפרויקט נשתמש בכלים של למידה עמוקה כדי לנתח אותות אופטיים בזמן, לזהות תבניות ודינמיקה, ולשחזר מידע שאינו נגיש ישירות מהמדידה.

מטרות הפרויקט

פיתוח ואימון של מודלים מבוססי למידה עמוקה לניתוח ולחיזוי של אותות אופטיים בממד הזמן. הסטודנטים יעבדו עם נתונים ניסיוניים וסינתטיים ממערכות של פולסים אולטרה-מהירים, ילמדו לזהות מאפיינים של האות, לשחזר את הצורה הזמנית שלו ולנבא את התפתחותו. בהמשך ייבחנו שימושים כגון סיווג מצבי מערכת, זיהוי חריגות ושחזור פרמטרים פיזיקליים מתוך המדידות.

נושאים נלמדים

עיבוד אותות בזמן ובתדר; טרנספורם פורייה; יסודות באופטיקה של פולסים אולטרה-מהירים; הכנת נתונים ונרמול; רשתות נוירונים; רשתות קונבולוציה; רשתות לניתוח סדרות זמן; מנגנוני attention; אימון, ולידציה ובדיקת מודלים; הערכת ביצועים; עבודה ב-Python עם PyTorch או TensorFlow; ניתוח והשוואה בין נתונים ניסיוניים לנתונים סינתטיים.

מספר פרויקט: 83 | Data Engineering and AI

בינה מלאכותית ואופטימיזציה חכמה לניתוח התאמה בין תהליכים לנתונים
AI and Intelligent Optimization for Process-Data Alignment

פרטי הנחיה

שם המנחה המלא: איציק כהן

דוא"ל המנחה: izack.cohen@biu.ac.il

ראש/ת המעבדה / אחראי/ת אקדמי/ת: איציק כהן

דוא"ל ראש/ת המעבדה: izack.cohen@biu.ac.il

לרישום יש להזין: מספר פרויקט 83 | שם המנחה המלא: איציק כהן
ראש/ת המעבדה: איציק כהן | הקבלה והשיבוץ מותנים באישור שניהם.

רקע לפרויקט

מערכות מידע ובסיסי נתונים מתעדים כמויות עצומות של אירועים המתארים תהליכים אמיתיים: טיפול בלקוחות, ייצור, לוגיסטיקה, תהליכים רפואיים, מערכות פיננסיות ועוד. אולם התהליך שמבוצע בפועל אינו תמיד תואם את התהליך שתוכנן מראש.

למי הפרויקט מתאים? לסטודנטים שהבינו טוב והתחברו לקורסי האופטימיזציה בדגש על מודלים דטרמיניסטיים ומבני נתונים ואלגוריתמים וגם הצליחו במקצועות אלו. לאנשים יצירתיים, עם יכולת בנייה ופיתוח.

הפרויקט עוסק בשאלות מרכזיות בדאטה סיינס, ניהול תהליכים עסקיים ובינה עסקית: כיצד ניתן לזהות באופן אוטומטי היכן התהליך בפועל סטה מהמודל? כיצד ניתן למצוא את ההסבר המדויק ביותר לסטייה מתוך מספר עצום של אפשרויות?

צוות הפרויקט יפתח אלגוריתמים חכמים לפתרון בעיית Alignment-Based Conformance Checking, משימה בתחום כריית התהליכים. מטרת המשימה למצוא את ההתאמה הטובה ביותר בין רצף אירועים שנצפה בנתונים לבין ההתנהגות החוקית המוגדרת במודל התהליך.

הפרויקט משלב תחומים מרכזיים בבינה מלאכותית ובמדעי הנתונים: חיפוש חכם באמצעות (A^*) ואלגוריתמים היוריסטיים, אופטימיזציה באמצעות Linear Programming ו-Mixed-Integer Linear Programming (MILP), ניתוח נתוני אירועים אמיתיים, השוואה ניסויית בין אלגוריתמים, פיתוח שיטות היברידיים המשלבות חיפוש ואופטימיזציה, תכנון חתכים, חסמים ופירוקים אלגוריתמיים לשיפור זמני הריצה.

הסטודנטים יממשו וישוו מספר גישות לפתרון הבעיה, ינתחו באילו סוגי מופעים כל שיטה מצליחה או נכשלת, וינסו לפתח שיפורים חדשים.

האלגוריתמים ייבחנו על נתוני תהליכים אמיתיים וסינתטיים. במסגרת הניסויים ינתחו זמן הריצה, צריכת הזיכרון, איכות החסמים, גודל מרחב החיפוש ומספר המופעים שניתן לפתור באופן אופטימלי.

הבעיה משלבת שתי גישות מרכזיות לפתרון בעיות בבינה מלאכותית: חיפוש במרחב מצבים – בדומה לאלגוריתמים המשמשים בתכנון אוטומטי, ניווט ומשחקים. אופטימיזציה מתמטית – בניית מודל מתמטי ופתרונה באמצעות פותרי אופטימיזציה מתקדמים (סולברים).

אחת משאלות המחקר המרכזיות תהיה: מתי עדיף לפתור את הבעיה באמצעות חיפוש חכם, מתי באמצעות MILP, והאם שילוב בין השיטות יכול להיות יעיל יותר משתיהן?

תוצרי הפרויקט:

בסיום הפרויקט תהיה בידי הסטודנטים מערכת מלאה הכוללת: מימוש של מספר אלגוריתמים לפתרון הבעיה (חובה)

השוואה ניסויית בין האלגוריתמים (חובה)
ניתוח מאפייני הנתונים המשפיעים על ביצועי האלגוריתמים (חובה)
שיפורים לשיטות הקיימות באמצעות שיטות מתקדמות,
הצגה ויזואלית של alignments ושל הסטיות שהתגלו בתהליך.

מטרות הפרויקט

לפתח ולהשוות שיטות מבוססות אופטימיזציה מתמטית ובינה מלאכותית באמצעות חיפוש חכם לפתרון יעיל של בעיית Alignment-Based Conformance Checking.

נושאים נלמדים

כריית תהליכים, פיתוח אלגוריתמי, אופטימיזציה.

מספר פרויקט: 84 | Data Engineering and AI

בינה מלאכותית מונחית תהליך: שילוב ידע חיצוני ברשתות עמוקות ובמודלי דיפוזיה
Process-guided AI: Integrating external knowledge into deep and diffusion models

פרטי הנחיה

שם המנחה המלא: איציק כהן

דוא"ל המנחה: izack.cohen@biu.ac.il

ראש/ת המעבדה / אחראי/ת אקדמי/ת: איציק כהן

דוא"ל ראש/ת המעבדה: izack.cohen@biu.ac.il

לרישום יש להזין: מספר פרויקט 84 | שם המנחה המלא: איציק כהן
ראש/ת המעבדה: איציק כהן | הקבלה והשיבוץ מותנים באישור שניהם.

רקע לפרויקט

רשתות למידה עמוקה ומודלי דיפוזיה לומדים בדרך כלל מתוך הנתונים בלבד. בתהליכים קיים לעיתים ידע חיצוני משמעותי כמו איזה פעילויות יכולות להתרחש בכל שלב ומהו הסדר האפשרי ביניהן, או אילו רצפי פעילויות אינם חוקיים.

לדוגמה, בתהליך של הרכבת מוצר, ביצוע טיפול, הכנת מזון או טיפול בבקשה ארגונית, לא כל פעילות יכולה להתרחש בכל שלב. ידע כזה יכול להיות מיוצג באמצעות: חוקים לוגיים או זמניים, חוקים שנוסחו או חולצו באמצעות LLM ולאחר מכן אומתו, רשת פטרי, אוטומט, מכונת מצבים או גרף.

מטרת הפרויקט היא לבדוק באופן האם וכיצד שילוב ידע תהליכי יכול לשפר את הביצועים של מודלי למידה.

הסטודנטים המתאימים לפרויקט זה:

סטודנטים חזקים בעלי ניסיון תיאורטי ומעשי קודם בלמידה עמוקה.

ניסיון מעשי משמעותי: ביצוע אימון או fine-tuning של רשת, השלמה עצמאית של פרויקט קודם בלמידת מכונה או למידה עמוקה, יכולת לטעון dataset, לבנות data pipeline, לאמן מודל ולהעריך את ביצועיו, ניסיון בעבודה עם מודלים מאומנים מראש, יכולת עבודה ב-Python, Git, וסביבת Linux, ניסיון בשימוש ב-GPU ובהתמודדות עם בעיות זיכרון ותהליכי אימון.

הפרויקט דורש גם לקרוא לעומק מאמרים מדעיים באנגלית ולממש שיטות המתוארות בהם, הבנה של train, validation, test.

אם ניסיונכם מסתכם בקורס תאורטי, שימוש ב-API או prompting יהיה לכם קשה להצליח בפרויקט.

המחקר יתבסס על datasets פרוצדורליים ממאמרים קודמים. ניתן לבחור נתוני וידאו (עדיפות נמוכה בגלל המורכבות), רצפי אירועים, סדרות מאפיינים או ייצוגים מולטימודליים. אפשרות נוספת היא להשתמש ב-event logs קיימים שבהם תהליך מיוצג כרצף אירועים.

כדי להשוות תרומת ידע חיצוני יושוו ארבעה מצבים מרכזיים עבור אותו dataset, אותה משימה ואותם מדדי הערכה:

1. מודל קיים ללא Fine-Tuning

הפעלת מודל מאומן מראש במתכונת zero-shot או באמצעות רכיבי classification קיימים, ללא התאמת משקלי המודל ל-dataset הנבחר.

2. מודל ללא Fine-Tuning אך עם תוספת ידע תהליכי

המודל הבסיסי יישאר ללא שינוי, אך תחזיותיו יונחו או יתוקנו באמצעות חוקים, גרף, רשת פטרי, אוטומט או ידע שהופק באמצעות LLM (יתכן שיושאו ייצוגים שונים של ידע חיצוני).

3. מודל לאחר Fine-Tuning

התאמת המודל לנתוני האימון של ה-dataset, ללא שימוש מפורש בידע תהליכי חיצוני. זה המצב המקובל כיום ובו המודל לומד את התהליך על בסיס דוגמאות.

4. מודל לאחר Fine-Tuning בתוספת ידע תהליכי

שילוב בין התאמת המודל לנתונים לבין שימוש מפורש בחוקים או במודל התהליך. האם במקרה כזה ידע חיצוני תורם משמעותית?

מבנה זה יאפשר להפריד בין התרומה של ה-fine-tuning לבין התרומה של הידע החיצוני ולבדוק האם הם משלימים זה את זה.

הסטודנטים יממשו מספר גישות שונות לשילוב ידע:

- א. שילוב באמצעות Post-Processing המודל מפיק תחילה תחזיות רגילות, ולאחר מכן מופעל אלגוריתם חיצוני המתקן או מדרג אותן מחדש בהתאם למודל התהליך. דוגמא: מחיקת תחזיות המפרות חוק תהליכי.
- ב. שילוב בזמן ההסקה הידע התהליכי ישפיע על תהליך יצירת התחזית עצמו, בלי לאמן מחדש את כל המודל. דוגמא: סינון של פעילויות שאינן אפשריות במצב הנוכחי או שינוי ההסתברויות.
- ג. שילוב בזמן הלמידה הידע ישולב ישירות בתהליך האימון או ה-fine-tuning. דוגמא: מתן קנס לתחזיות המפרות את מודל התהליך.

תוצרים:

1. benchmark מתועד וניתן לשחזור (חובה).
2. מציאת שיטה המשפרת באופן מובהק את כל ה-baselines (פרויקט מצויין).

מטרות הפרויקט

ביצוע השוואת שיטות לשילוב ידע תהליכי חיצוני ברשתות למידה עמוקה ובמודלי דיפוזיה.

נושאים נלמדים

מודלי תהליך, שילוב ידע חיצוני עם מודלי למידה.

מספר פרויקט: 101 | Data Engineering and AI

חיפוש מבוסס-קונפליקטים לתזמון פרויקטים מוגבלי-משאבים

Conflict-Based Search for the Resource-Constrained Project Scheduling Problem

פרטי הנחיה

שם המנחה המלא: Ido Lublin

דוא"ל המנחה: ido.lublin@gmail.com

ראש/ת המעבדה / אחראי/ת אקדמי/ת: איציק כהן ודור עצמון

דוא"ל ראש/ת המעבדה: dor.atzmon@biu.ac.il

לרישום יש להזין: מספר פרויקט 101 | שם המנחה המלא: Ido Lublin

ראש/ת המעבדה: איציק כהן ודור עצמון | הקבלה והשיבוץ מותנים באישור שניהם.

רקע לפרויקט

בעיית תזמון פרויקטים תחת אילוצי משאבים - (Resource-Constrained Project Scheduling Problem) RCPSP היא אחת מבעיות האופטימיזציה הקומבינטורית המרכזיות בהנדסת תעשייה ובניהול פרויקטים. הבעיה עוסקת בקביעת לוח זמנים לביצוע משימות בעלות אילוצי קדימות, תחת משאבים בעלי קיבולת מוגבלת, במטרה למזער את זמן סיום הפרויקט הכולל (Makespan).

בעיה זו היא NP-Hard, ושיטות האופטימיזציה המקובלות לפתרונה, כגון תכנות לינארי בשלמים (MILP) ואלגוריתמי Branch and Bound, סובלות לעיתים קרובות מגידול מעריכי בזמני הריצה ומתקשות לפתור מופעים מורכבים בזמן סביר.

אלגוריתם CBS (Conflict-Based Search) הוא אלגוריתם חיפוש דו-שכבתי שפותח עבור בעיות תכנון מסלולים מרובי-סוכנים (Multi-Agent Path Finding – MAPF). האלגוריתם פועל בשתי רמות: ברמה הנמוכה נמצא פתרון בנפרד לכל סוכן, וברמה הגבוהה מזהים קונפליקטים בין הפתרונות ונפתרים בהדרגה על ידי פיצול הבעיה והוספת אילוצים, עד להתכנסות לפתרון חסר-קונפליקטים.

פרויקט זה עוסק בשיפור אלגוריתם CBS שהותאם לפתרון בעיית RCPSP. במסגרת הפרויקט ילמדו הסטודנטים את המודל הקיים ויחקרו כיצד ניתן להתאים ולהטמיע רעיונות ושיפורים שפותחו עבור CBS בבעיות MAPF לצורך שיפור ביצועי האלגוריתם ב-RCPSP. העבודה תכלול פיתוח אסטרטגיות לפתרון קונפליקטים, שילוב יוריסטיקות, חוקי דומיננטיות, במטרה להשיג ביצועים תחרותיים ביחס לשיטות המובילות בספרות.

מטרות הפרויקט

מטרת הפרויקט היא לפתח ולייעל אלגוריתם חיפוש מבוסס קונפליקטים (CBS) המותאם לפתרון בעיית RCPSP. במסגרת העבודה ילמדו הסטודנטים את הספרות בתחומי MAPF ו-RCPSP, ויבחנו כיצד ניתן לעשות אדפטציה של רעיונות אלגוריתמיים מעולם תכנון המסלולים לפתרון בעיית התזמון. העבודה בנוסף תתעסק בשיפור האלגוריתם על ידי פיתוח אסטרטגיות פיצול ויצירת אילוצים לפתרון קונפליקטים הנובעים ממגבלות משאבים, בפיתוח ושילוב יוריסטיקות קבילות וקונסיסטנטיות להנחיית החיפוש וחוקי דומיננטיות לגיזום יעיל של עץ החיפוש. כל הפיתוחים ימומשו על ידי הסטודנטים בקוד ויבדקו על מאגרי בנצ'מרק סטנדרטיים, תוך השוואה לאלגוריתמים המובילים בספרות.

נושאים נלמדים

בעיית תזמון פרויקטים תחת אילוצי משאבים - (Resource-Constrained Project Scheduling Problem) RCPSP

אלגוריתם חיפוש מבוסס קונפליקטים (Conflict-Based Search – CBS)

בעיות תכנון מסלולים מרובי-סוכנים (Multi-Agent Path Finding – MAPF)

פיתוח יוריסטיקות קבילות וקונסיסטנטיות (Admissible and Consistent Heuristics)

חוקי דומיננטיות (Dominance Rules)

Data Engineering and AI | מספר פרויקט: 113

מתי סוכני בינה מלאכותית משתנים: השפעת הסביבה והחשיפה החברתית
When AI Agents Change: The Effects of Environment and Social Exposure

פרטי הנחיה

שם המנחה המלא: Ron Abramovich
דוא"ל המנחה: ron.abramovich96@gmail.com
ראש/ת המעבדה / אחראי/ת אקדמי/ת: shahar somin
דוא"ל ראש/ת המעבדה: somin.shahar@gmail.com

לרישום יש להזין: מספר פרויקט 113 | שם המנחה המלא: Ron Abramovich
ראש/ת המעבדה: shahar somin | הקבלה והשיבוץ מותנים באישור שניהם.

רקע לפרויקט

When an autonomous AI agent is created, its behaviour is shaped by characteristics defined by its developers. These may include its prompt, memory files, goals, available skills and tools, access permissions, and predefined behavioural profile. We usually assume that these characteristics will remain stable throughout the agent's operational lifetime unless a human explicitly changes them. However, it is not clear whether this assumption remains valid after the agent operates in different environments and repeatedly interacts with other agents. Could a risk-averse agent become more willing to take risks after observing successful risk-taking agents? Could a trusting agent become less trusting after interacting with dishonest or manipulative agents? Could a cooperative agent become more competitive in an adversarial environment, or a cautious agent become more willing to use uncertain information after seeing others benefit from it? These examples raise a fundamental question: can autonomous agents develop new and persistent behavioural characteristics through experience and social exposure alone?

מטרות הפרויקט

The goal of this project is to determine whether autonomous AI agents evolve after being exposed to their environment and to other agents, even when no new instructions are provided by a human operator. Our lab has developed a controlled system for managing interactions among agents and for studying how their behaviour changes over time. Using this system, we will examine which aspects of an agent's behaviour, characteristics, and activity profile change through social and environmental exposure, the extent and intensity of these changes, and how long they persist. We will also investigate the mechanisms that determine whether such changes occur, how strongly they affect the agent, and whether the agent eventually returns to its original behavioural profile or develops a new and stable one.

נושאים נלמדים

Students will gain practical experience in designing and running controlled experiments with autonomous AI agents. They will learn how agents are defined through prompts, memory, skills, tools, and behavioural settings, and how these components influence the agents' decisions. They will also learn how to collect and analyse behavioural data over time, compare agents across different conditions, and distinguish short-term reactions from persistent behavioural change. Through the project, students will develop skills in experimental design, data analysis, programming, and the evaluation of complex AI systems. They will also gain a deeper understanding of how social interaction, feedback, and environmental conditions can shape the behaviour of autonomous agents.

מספר פרויקט: 105 | Data Engineering and AI

מערכות בטוחות לזיהוי אובייקטים באמצעות אימות פורמלי

Scaling Formal Verification of Object Detection to State-of-the-Art OD Systems

פרטי הנחיה

שם המנחה המלא: Prof. Hillel Kugler

דוא"ל המנחה: hillelk@biu.ac.il

ראש/ת המעבדה / אחראי/ת אקדמי/ת: Prof. Hillel Kugler

דוא"ל ראש/ת המעבדה: hillelk@biu.ac.il

לרישום יש להזין: מספר פרויקט 105 | שם המנחה המלא: Prof. Hillel Kugler
ראש/ת המעבדה: Prof. Hillel Kugler | הקבלה והשיבוץ מותנים באישור שניהם.

רקע לפרויקט

Object detection networks must both classify objects and localize them using bounding boxes, making their correctness properties substantially more complex than those of image classifiers. The NFM 2026 work "Towards Formal Verification of Deep Neural Networks for Object Detection" introduced sound and complete robustness queries for misdetection, misclassification, and over-detection, encoded intersection-over-union (IoU) constraints as verifier-compatible neural-network layers, and evaluated the approach using Alpha-Beta-CROWN. The published work deliberately focused on pre-processing outputs of comparatively compact detectors and identified large production detectors and post-processing as major limitations. This project will carry that research forward to substantially larger and state-of-the-art object-detection systems, with particular emphasis on the latest YOLO family and comparison with YOLO11. Students will construct an automated translation and verification pipeline for selected YOLO models, formally specify robustness of localization, class prediction, confidence and detection count, and develop scalable decompositions, bounding strategies and verification-aware model abstractions. YOLO26 is especially relevant because its default one-to-one head supports end-to-end, NMS-free inference, creating an opportunity to verify a more complete deployed detection pipeline while also comparing it with the traditional one-to-many/NMS path. The project will evaluate correctness, scalability, verified robustness and counterexample quality on standard and safety-relevant datasets.

מטרות הפרויקט

The goal is to extend the NFM 2026 formal-verification framework from small and medium object detectors to modern, large-scale YOLO architectures. The project will support at least YOLO26n and YOLO26s, and will aim to progress to larger YOLO26 variants as resources permit. It will adapt the IoU and class-property encodings to the multi-scale, multi-object outputs used by YOLO, provide a reproducible export path from Ultralytics/PyTorch to a verifier-compatible representation, and evaluate Alpha-Beta-CROWN and optional additional verification backends. The main research objective is not merely to run an existing verifier on a larger model, but to design sound reductions, output filtering rules, compositional queries, bound reuse and architecture-aware abstractions that make verification feasible without invalidating the formal guarantees. Deliverables: • A reproducible pipeline that loads selected pretrained or fine-tuned YOLO26 and YOLO11 detectors, exports the verification-relevant computation graph, and generates formal robustness queries • Support for formal properties covering misdetection, misclassification and over-detection, including IoU, confidence-score and object-count constraints • Verification of the YOLO26 one-to-one NMS-free detection head, with a clearly documented trusted computing base and supported operations • A scalable query-decomposition method for multi-scale and multi-object detector outputs, including sound candidate-box selection or over-approximation

נושאים נלמדים

Object Detection methods

Formal verification

AI Engineering

Data Engineering and AI | מספר פרויקט: 118

שילוב של AI ואופטימיזציה לפתרון פאזלים של ריצוף
Hybrid AI and Mathematical Optimization for Solving Visual Tiling Puzzles

פרטי הנחיה

שם המנחה המלא: Prof. Hillel Kugler

דוא"ל המנחה: hillelk@biu.ac.il

ראש/ת המעבדה / אחראי/ת אקדמי/ת: Prof. Hillel Kugler

דוא"ל ראש/ת המעבדה: hillelk@biu.ac.il

לרישום יש להזין: מספר פרויקט 118 | שם המנחה המלא: Prof. Hillel Kugler
ראש/ת המעבדה: Prof. Hillel Kugler | הקבלה והשיבוץ מותנים באישור שניהם.

רקע לפרויקט

Visual tiling puzzles require arranging a fixed set of geometric pieces so that they cover a target silhouette exactly, without gaps or overlap. They combine visual reasoning, combinatorial search, geometry, and optimization, and provide a compact but challenging benchmark for comparing artificial intelligence with exact mathematical methods. This project will design and evaluate AI-based solvers for both continuous puzzles and grid-based puzzles, compare them rigorously with mathematical optimization and exact-search methods, and investigate hybrid algorithms that combine learned guidance with exact reasoning.

מטרות הפרויקט

The goal is to develop a unified experimental framework for solving Visual puzzles using AI, exact optimization, and hybrid AI-optimization methods. The project will determine where each paradigm succeeds or fails, and will design hybrid techniques in which AI predicts promising piece placements, variable orderings, decompositions, , while an exact solver enforces coverage, containment, non-overlap, and piece-usage constraints. The final system should provide solutions, visualizations, runtime statistics.

נושאים נלמדים

Optimization, Formal Reasoning, Deep Learning, Tiling Algorithms

מספר פרויקט: 120 | Data Engineering and AI

דגימה מגוונת של אובייקטים תלת מימדיים

Diverse Sampling of 3D Artifacts

פרטי הנחיה

שם המנחה המלא: גל וינוגרד
דוא"ל המנחה: gal.vinograd@biu.ac.il
ראש/ת המעבדה / אחראי/ת אקדמי/ת: ד"ר איתן פתיה
דוא"ל ראש/ת המעבדה: ethan.fetaya@biu.ac.il

לרישום יש להזין: מספר פרויקט 120 | שם המנחה המלא: גל וינוגרד
ראש/ת המעבדה: ד"ר איתן פתיה | הקבלה והשיבוץ מותנים באישור שניהם.

רקע לפרויקט

In the setting of diffusion and flow matching models, diverse sampling has become increasingly important for casual and professional users alike. Specifically, diverse sampling is the task of generating (or sampling) n objects using some underlying model while maximizing some distance function between them (known as the kernel). For example, if a Midjourney user asks to generate 4 different variants of "a teacup pink cat", they expect the variants to be substantially different in style, scene, story, etc.

We recently devised a novel diverse sampling algorithm called EDDY that uses turbulences (or eddies) to push apart samples as they are generated with minimal quality loss (see <https://galvinograd.github.io/eddy>). As a proof of concept, we tested EDDY only on image generation and left other more exotic modalities for future work.

For this project, we would like to integrate EDDY in 3D artifact generative models. We believe that the main challenge would be correctly identifying which kernel best represents differences between 3D samples while being fast and generic enough to work in practice.

מטרות הפרויקט

Integrating a novel diverse sampling algorithm in 3D generative models.

נושאים נלמדים

Diffusion/FM models, steering and guidance, 3D generative models

מספר פרויקט: 126 | Data Engineering and AI

זיהוי גמגום דיבור

Stuttering detection

פרטי הנחיה

שם המנחה המלא: Sharon Gannot
דוא"ל המנחה: sharon.gannot@biu.ac.il
ראש/ת המעבדה / אחראי/ת אקדמי/ת: Sharon Gannot
דוא"ל ראש/ת המעבדה: sharon.gannot@biu.ac.il

לרישום יש להזין: מספר פרויקט 126 | שם המנחה המלא: Sharon Gannot
ראש/ת המעבדה: Sharon Gannot | הקבלה והשיבוץ מותנים באישור שניהם.

רקע לפרויקט

גמגום הינו תופעה הפוגמת בתקשורת בין אנשים ובין אדם למכונה. נקודת הפתיחה תהיה המאמר
Whister: Using Whisper's representations for Stuttering detection
בהמשך בהתבסס על גילוי המיקום המדויק של תחילת הגמגום, מערכת ביופידבק שתעשזזר למגמגם
לדבר באופן רגיל.

מטרות הפרויקט

פיתוח מערכת לזיהוי גמגום שפועלת בשפות שונות, כולל עברית.

נושאים נלמדים

עיבוד דיבור, למידה עמוקה, ייצוג אותות, מערכות ביופידבק

מספר פרויקט: 10 | BioEngineering

שימוש בלמידת מכונה לחיזוי התאוששות חיידקי המעי לאחר טיפול אנטיביוטי
Machine Learning-Driven Identification of Gut Microbiome Keystone Species for Personalized Antibiotic Recovery

פרטי הנחיה

שם המנחה המלא: פורת יוסף חנני
דוא"ל המנחה: porath188@gmail.com
ראש/ת המעבדה / אחראי/ת אקדמי/ת: אור לוי
דוא"ל ראש/ת המעבדה: orr.levy@biu.ac.il

לרישום יש להזין: מספר פרויקט 10 | שם המנחה המלא: פורת יוסף חנני
ראש/ת המעבדה: אור לוי | הקבלה והשיבוץ מותנים באישור שניהם.

רקע לפרויקט

טיפול באנטיביוטיקה מיועד לאלימינציה של חיידקים פתוגניים, אך בפועל פוגע גם באוכלוסיות חיידקים ידידותיות וחיוניות במיקרוביום במערכת העיכול. לרוב, אוכלוסיות המיקרואורגניזמים השונים במעיים מתאוששות, והמאזן האקולוגי במעי חוזר לקדמותו לאחר זמן החלמה ומתן פרוביוטיקה. אך לעיתים פגיעה משמעותית במיקרוביום בעקבות טיפול אנטיביוטי ממושך גורמת להפרעות עיכול ואף בעיות רפואיות מורכבות יותר כמו קוליטיס.

במיקרוביום, בדומה למערכות אקולוגיות אחרות, קיימים "Keystone species" – מיני אורגניזמים בעלי חשיבות אקולוגית רבה המהווים מרכיב יסודי במערכת, ופגיעה בהם עלולה להביא לפגיעה במינים נוספים ולשיבוש היציבות והמאזן האקולוגי. פרויקט זה מתמקד באפיון "Keystone species" הנפגעים מטיפול אנטיביוטי, ובפיתוח מודלים חישוביים לניבוי אסטרטגיות תזונתיות או פרוביוטיות מותאמות אישית לשיקום מהיר ויעיל של המיקרוביום. השילוב של מדעי הנתונים עם מידע ביולוגי יאפשר הבנה עמוקה של דפוסי הפגיעה במיקרוביום ותמיכה בפיתוח רפואה מותאמת אישית.

מטרות הפרויקט

לזהות מינים קריטיים (keystone species) הנפגעים מטיפול אנטיביוטיקה ולפתח מודלים מבוססי למידת מכונה לניבוי טיפול מיטבי לשיקום מהיר של המיקרוביום התומך ב"מיני המפתח" במערכת במקרים שונים של פגיעה.

נושאים נלמדים

- עיבוד וניתוח נתוני ריצוף מטאגנומי של חיידקים.
- שימוש בכלים סטטיסטיים ובשיטות למידת מכונה לצורך חיזוי פגיעה והתאוששות של המיקרוביום לאחר טיפול אנטיביוטי.
- הערכת ביצועי מודלים חישוביים, כולל חלוקה ל-`training/test/validation`, מדדי דיוק, חשיבות משתנים ויכולת הכללה.
- ניתוח רשתות אקולוגיות של המיקרוביום לזיהוי קשרים בין מינים וזיהוי מינים מרכזיים במערכת.
- חשיבה יישומית בתחום הרפואה המותאמת אישית, בדגש על התאמת אסטרטגיות שיקום מיקרוביום באמצעות תזונה, פרה-ביוטיקה או פרוביוטיקה.
- מבנה והרכב מיקרוביום המעי ותפקידו בשמירה על בריאות האדם.
- מושגים באקולוגיה מיקרוביאלית, כולל Keystone species, יציבות קהילתית, שיקום לאחר הפרעה וקשרים בין מינים.

מספר פרויקט: 13 | BioEngineering

חישה אופטית של שרירי האמה מרחוק לזיהוי תנועת אצבעות לצורך הנחיית זרוע רובוטית.
Remote Optical Sensing of Forearm Muscles for Finger Movement Recognition in Robotic Arm Control.

פרטי הנחיה

שם המנחה המלא: Laurie Mesika
דוא"ל המנחה: lorimesika@gmail.com
ראש/ת המעבדה / אחראי/ת אקדמי/ת: Nisan Ozana
דוא"ל ראש/ת המעבדה: nisan.ozana@biu.ac.il

לרישום יש להזין: מספר פרויקט 13 | שם המנחה המלא: Laurie Mesika
ראש/ת המעבדה: Nisan Ozana | הקבלה והשיבוץ מותנים באישור שניהם.

רקע לפרויקט

ממשקי אדם-מכונה (HMI) ומערכות שליטה בזרועות רובוטיות או תותבות (פרוטזות) מתבססים באופן מסורתי על חיישני מגע המוצמדים לעור, כגון אלקטרודות למדידת הפעילות החשמלית של השריר (sEMG). בעוד שחיישנים אלו נפוצים מאוד, הם סובלים מחסרונות מעשיים משמעותיים: הם דורשים מגע ישיר וממושך עם העור, רגישים לזיעה, לתזוזה מכנית של האלקטרודה, ומייצרים אי-נוחות בשימוש יומיומי.

כחלופה לכך, בשנים האחרונות מתפתחות טכנולוגיות חישה אופטיות מרחוק (ללא מגע). כאשר אור לייזר פוגע ברקמה ביולוגית, האור המפוזר ממנה מושפע באופן ישיר מהתנועות הדינמיות המתרחשות מתחת לפני השטח. תנועות אלו כוללות הן את השינויים המכניים הזעירים במבנה סיבי השריר בזמן כיווץ והן את שינויי זרימת הדם הנלווים לפעילות זו.

אזור האמה (Forearm) עשיר בשרירים האחראיים על הפעלת אצבעות כף היד. פרויקט זה מציע לנצל את עושר המידע הקיים באות האופטי החוזר מהאמה כדי לזהות ממרחק את הפעילות השרירית הזו. באמצעות צילום וידאו של האות האופטי ועיבודו בעזרת מודלים מתקדמים של למידת מכונה ולמידה עמוקה, ניתן יהיה לנבא ולסווג איזו תנועת אצבעות מבוצעת בפועל, ולתרגם אותה בזמן אמת לפקודת תנועה עבור זרוע רובוטית.

מטרות הפרויקט

מטרת על של הפרויקט היא שימוש במערכת אופטית מבוססת לייזר ובניית מודל סיווג, המסוגל לזהות ולסווג תנועות אצבעות ספציפיות ממרחק (ללא מגע), לצורך תרגומן לפקודות הפעלה בזרוע רובוטית.

נושאים נלמדים

עיבוד אותות, למידת מכונה, אופטיקה ביורפואית, מתודולוגית עבודה, אנטומיה וביומכניקה של הגפה העליונה, BCI.

מספר פרויקט: 49, 107 | BioEngineering

שחזור שמע ברמת נאמנות גבוהה המבוסס על למידת מכונה מחישה אקוסטית
High-Fidelity ML-Based Audio Reconstruction from Rolling Shutter Laser Speckle Acoustic Sensing

פרטי הנחיה

שם המנחה המלא: ד"ר ניסן אוזנה
דוא"ל המנחה: nisan.ozana@biu.ac.il
ראש/ת המעבדה / אחראי/ת אקדמי/ת: משה ברציאנסקי
דוא"ל ראש/ת המעבדה: brachem@biu.ac.il

לרישום יש להזין: מספר פרויקט 49 | שם המנחה המלא: ד"ר ניסן אוזנה
ראש/ת המעבדה: משה ברציאנסקי | הקבלה והשיבוץ מותנים באישור שניהם.

רקע לפרויקט

Our lab's novel method uses a low-cost rolling shutter CMOS camera to capture vibrating laser speckle patterns and reconstruct biological signals like heartbeat, lung sounds, and speech through correlation-based signal processing. While deep learning models have improved audio reconstruction, the overall quality of the reconstruction remains insufficient.

מטרות הפרויקט

In this work, we aim to enhance both the signal quality, and advance our reconstruction ability via the latest state-of-the-art models and architectures. The metrics that will reflect the improved performance are improved SISNR, SDR, and STOI compared to the baselines.

נושאים נלמדים

Rolling Shutter, Laser Speckle, Acoustic Sensing, Deep Learning, Generative AI

מספר פרויקט: 72 | BioEngineering

למידת מכונה ואנליזת רדיומיקס בהדמיות MRI מוחיות לניבוי תוצאות ניתוח בחולים עם גידולים מוחיים

Machine learning and brain MRI radiomics for predicting surgical outcomes in patients with brain tumors

פרטי הנחיה

שם המנחה המלא: ניצן בר לב

דוא"ל המנחה: nitsan.bar.lev@gmail.com

ראש/ת המעבדה / אחראי/ת אקדמי/ת: ד"ר יערה ארז

דוא"ל ראש/ת המעבדה: Yaara.Erez@biu.ac.il

לרישום יש להזין: מספר פרויקט 72 | שם המנחה המלא: ניצן בר לב
ראש/ת המעבדה: ד"ר יערה ארז | הקבלה והשיבוץ מותנים באישור שניהם.

רקע לפרויקט

גידולים מוחיים משפיעים לא רק על הרקמה בה הם ממוקמים, אלא גם על תפקוד מוחי נרחב יותר ועל תפקוד המטופל ואיכות חייו. היכולת לנבא את תוצאות הניתוח להסרת הגידול עוד בטרם ההתערבות הכירורגית היא קריטית לתכנון הטיפול ולאיוון מיטבי בין הוצאה מרבית של הגידול, לבין שמירה על איכות החיים והתפקוד לאחר הניתוח. אולם, כיום הערכה זו נשענת בעיקר על פרמטרים כגון גודל ומיקום הגידול, בשילוב עם מבחני נייר ועט ייעודיים הדורשים זמן ומשאבים רבים.

רדיומיקס (Radiomics) היא גישה חישובית המאפשרת חילוץ מספר גדול של פיצ'רים מתמטיים מתוך תמונות רפואיות, כמו תמונות מבוססות תהודה מגנטית (MRI). שיטה זו מאפשרת לחלץ מידע עשיר ונסתר מהעין האנושית כגון עוצמה (intensity), צורה (shape) ומרקם (texture), מתוך הדמיות מבניות של המוח שנאספות כחלק מהפרקטיקה הקלינית. מידע כמותי זה יכול לשמש כקלט למודלים של למידת מכונה לצורך משימות ניבוי וסיווג מורכבות.

בפרויקט נבחן את היכולת להשתמש ברדיומיקס ככלי חישובי להערכה אובייקטיבית של תוצאות הניתוח. לצורך כך, נחלץ פיצ'רים מאזורים מוחיים שונים (כמו אזור הגידול עצמו ורשתות מוחיות אחרות). מטרת העל היא לשפר ולהעשיר את המידע הזמין והאובייקטיבי מתוך ההדמיות הקליניות הסטנדרטיות, ובכך ליעל את התכנון הניתוחי ולשפר את תהליך קבלת ההחלטות הקליניות.

מקורות:

1. Mayerhoefer, M. E., Materka, A., Langs, G., Häggström, I., Szczypiński, P., Gibbs, P., & Cook, G. (2020). Introduction to radiomics. *Journal of Nuclear Medicine*, 61(4), 488-495.

2. Mandal, A. S., Wiener, C., Assem, M., Romero-Garcia, R., Coelho, P., McDonald, A., ... & Erez, Y. (2024). Tumour-infiltrated cortex participates in large-scale cognitive circuits. *cortex*, 173, 1-15.

מטרות הפרויקט

מטרת הפרויקט היא יישום של מודלי למידת מכונה על מנת לבחון את הקשר בין מאפייני רדיומיקס בהדמיות MRI טרום-ניתוחיות, לבין תוצאות ניתוח להוצאת גידול מוחי. בתוך כך, נבחן האם ניתן לנבא באופן אובייקטיבי את התוצאות הקליניות והתפקודיות לאחר הניתוח ישירות מתוך ההדמיה הקלינית השגרתית. שלבי הפרויקט יכללו עיבוד מקדים של הדמיות מוחיות גולמיות, חילוץ מאפיינים כמותיים מאזורים מוחיים רלוונטיים, בנייה של מודל למידת מכונה, שימוש במודלים סטטיסטיים וויזואליזציה של התוצאות. דרישות: יכולת תכנות בפייתון. קורסים מומלצים: מבוא ללמידת מכונה, מדעי נתונים ביולוגיים, וכל קורס רלוונטי בתחום מערכות מוחיות ומדעי המוח. התוצרים הסופיים של הפרויקט: (1) פיתוח מודל למידת מכונה לניבוי התוצאות הקליניות והתפקודיות על בסיס מדדי הרדיומיקס. (2) חילוץ מדדי רדיומיקס מאזורים מוחיים רלוונטיים עבור כל מטופל, מתוך הדמיות מוחיות. (3) ניתוח השוואתי בין קבוצות מטופלים שונות תוך שימוש במודלים סטטיסטיים וניתוחי קורלציות. (4) ויזואליזציה של התוצאות. (5) הערכת היעילות של שימוש בהדמיות קליניות שגרתיות ככלי עזר להערכה טרום-ניתוחית של המטופל ולניבוי התוצאות הקליניות לאחר הניתוח.

נושאים נלמדים

- לימוד תאורטי וקריאה בספרות על מחקרים בתחום.
- אימון והערכה של מודלי למידת מכונה לניבוי ולסיווג (מודלים לינאריים: logistic regression, SVM, מודלים לא לינאריים: random forest, XGBoost וכו').
- היכרות עם נתוני MRI של חולים עם גידולים מוחיים.
- כתיבת קוד (פייתון) לעיבוד דאטה רפואי, ניתוח וויזואליזציה של הנתונים.

- עבודה מעשית עם כלים של neuroimaging לעיבוד וניתוח חישובי של הדמיות MRI (כמו FSL, MRICroGL, FreeSurfer).
- אנליזת רדיומיקס על אזורים מוחיים: עיבוד מקדים, סגמנטציה של אזורים, חילוף פיצ'רים ו-feature-selection.
- יישום ניתוחים סטטיסטיים להערכת קשרים בין מדדי ההדמיה לבין תוצאות הניתוח.

מספר פרויקט: 77 | BioEngineering

הפעלת אלגוריתמים של למידה עמוקה על מפות גנומיות של רקמות סרטניות לזיהוי אינטראקציות בין תאים.

Utilizing deep learning algorithms on genomic maps from cancer tissues to uncover cell-cell interactions.

פרטי הנחיה

שם המנחה המלא: טל גולדברג

דוא"ל המנחה: Talg9.7@gmail.com

ראש/ת המעבדה / אחראי/ת אקדמי/ת: ד"ר שחר אלון

דוא"ל ראש/ת המעבדה: shaharalon.mail@gmail.com

לרישום יש להזין: מספר פרויקט 77 | שם המנחה המלא: טל גולדברג
ראש/ת המעבדה: ד"ר שחר אלון | הקבלה והשיבוץ מותנים באישור שניהם.

רקע לפרויקט

גנומיקה מרחבית היא משפחה של טכנולוגיות המאפשרת לזהות את מיקום הגנים בתוך רקמות. לטכנולוגיות אלו חשיבות רבה בסרטן, כיוון שזה מאפשר לדעת איזה סוגי תאים נמצאים בתוך ביופסיות מחולים. המעבדה שלנו יצרה מפות גנומיות המציגות את הביטוי המרחבי של כ-300 גנים שונים ברקמות סרטניות, בתוך ומחוץ לתאים ברקמה. המידע מהמפות הגנומיות יכול לשמש כקלט לרשתות נוירונים. בנייה איכותית של רשתות הנוירונים ואימון על גבי המפות הגנומיות יכולה לחשוף מידע על מצב התאים הנמצאים ברקמה. דוגמה למצב כזה היא אינטראקציה בין תאים מסוגים שונים, למשל תא ממערכת החיסון שנמצא קרוב לתא סרטני ומושפע ממנו ברמת ביטוי הגנים שלו. האם המפות הגנומיות יכולות לחשוף לא רק את סוגי התאים שנמצאים בתוך הרקמה הסרטנית, אלא גם את מצב התאים והאינטראקציה ביניהם?

מטרות הפרויקט

בפרויקט נפעיל שיטות של עיבוד תמונה לצורך התאמת המפות הגנומיות שישמשו כקלט לאלגוריתמים של למידה עמוקה. נממש כתיבת קוד ויישום של רשתות נוירונים, תוך אימון ושיפור הביצועים של המודל. נשתמש בכלים חישוביים לחלץ פרשנות ביולוגית מהרשתות, החל מזיהוי סוגי התאים ברקמה ובהמשך חשיפת אינטראקציות בין סוגי התאים השונים - האם התא הגיב ברמה הגנומית לתא הסמוך אליו על סמך התמונה שהוכנסה כקלט לרשת.

נושאים נלמדים

גנומיקה מרחבית, למידה עמוקה ורשתות נוירונים, ניתוח מידע גנומי, סיווג תאים וזיהוי אינטראקציות בין תאים, עיבוד תמונה, פרשנות של מודלים חישוביים, זיהוי מאפיינים וגנים משמעותיים לקבלת החלטות המודל, עבודה עם מידע ביולוגי רב-ממדי.

מספר פרויקט: 79 | BioEngineering

שימוש בלמידה עמוקה לסיווג מצבים מוחיים מתוך הקלטות EEG של פעילות מוחית
Using deep learning for decoding brain states from EEG recordings of brain activity

פרטי הנחיה

שם המנחה המלא: סבטלנה וולוצקי

דוא"ל המנחה: volotss@biu.ac.il

ראש/ת המעבדה / אחראי/ת אקדמי/ת: יערה ארז

דוא"ל ראש/ת המעבדה: Yaara.Erez@biu.ac.il

לרישום יש להזין: מספר פרויקט 79 | שם המנחה המלא: סבטלנה וולוצקי
ראש/ת המעבדה: יערה ארז | הקבלה והשיבוץ מותנים באישור שניהם.

רקע לפרויקט

בפרויקט זה, הסטודנטים ישתמשו בנתוני EEG (electroencephalogram) שהוקלטו מנבדקים המבצעים משימות ממוחשבות שונות, על מנת לבנות מסווג על-בסיס למידה עמוקה המבחין בין מצבים מוחיים שונים, ובפרט מצבי עומס קוגניטיבי. אתגר חשוב בסיווג מבוסס EEG הוא שמסווגים המאומנים על משימה או נבדק מסוימים מכילים בצורה חלשה משימות או לנבדקים אחרים; בפרויקט זה נבחנת היכולת של מודלים של למידה עמוקה כגון EEGNet לזהות תבניות מורכבות תלויות-זמן באותות ה-EEG ובכך לשפר את יכולת ההכללה.

מטרות הפרויקט

מטרת הפרויקט היא לפתח קוד חישובי מבוסס למידה עמוקה לסיווג עומס קוגניטיבי מאותות EEG ולבחון הכללה מעבר לנבדקים, משימות, ונקודות זמן שונות. התוצרים הסופיים של הפרויקט: פייפליין של קוד פיתוח מבוסס למידה עמוקה (למשל EEGNet) הכולל עיבוד אותות, המאומן ומוערך על נתוני ה-EEG. תוצאות סיווג בתוך הקלטה בודדת כ-benchmark והכללה בין נבדקים, משימות, ונקודות זמן שונות.

נושאים נלמדים

- במסגרת הפרויקט הסטודנטים ידרשו לבצע את המטלות הבאות:
- לימוד תאורטי וקריאה בספרות על מחקרים בתחום.
 - היכרות עם ECG ועם מאגר הנתונים של הנבדקים.
 - לימוד והפעלה של כלים לניתוח EEG בפיתוח, כולל עיבוד מקדים של האות והכנת הנתונים לשימוש במסווג.
 - מימוש ואימון של מודל למידה עמוקה כגון רשת קונבולוציה קומפקטית (EEGNet) כמסווג.
 - שימוש במודלים סטטיסטיים וויזואליזציה להצגת התוצאות.

מספר פרויקט: 98 | BioEngineering

למידת מכונה לזיהוי מצבי מוח דינמיים מתוך הקלטות של פעילות מוחית חשמלית ברזולוציה גבוהה בזמן ובמרחב
Machine learning for identifying dynamic brain states from electrical brain activity recordings with high spatial and temporal resolution

פרטי הנחיה

שם המנחה המלא: ניצן בר לב

דוא"ל המנחה: nitsan.bar.lev@gmail.com

ראש/ת המעבדה / אחראי/ת אקדמי/ת: ד"ר יערה ארז

דוא"ל ראש/ת המעבדה: Yaara.Erez@biu.ac.il

לרישום יש להזין: מספר פרויקט 98 | שם המנחה המלא: ניצן בר לב
ראש/ת המעבדה: ד"ר יערה ארז | הקבלה והשיבוץ מותנים באישור שניהם.

רקע לפרויקט

המוח הוא מערכת דינמית, המאורגנת סביב תבניות פעילות שמשתנות במהירות לאורך זמן, גם כאשר אנו נמצאים במצב מנוחה, ללא גירוי חיצוני. מחקרים רבים הדגישו את החשיבות של האופן שבו איזורים מוחיים פועלים ביחד (קישוריות תפקודית), אך התייחסו לקישוריות זו כתכונה סטטית וקבועה. מחקרים עדכניים מדגישים כי דפוסי הקישוריות בין איזורי מוח שונים משתנים על פני הזמן ומשקפים מעברים בין מצבי מוח באופן דינמי (brain states).

באמצעות אלקטרודות המונחות ישירות על קליפת המוח בטכנולוגיה הנקראת intracranial EEG (iEEG), ניתן להקליט מחולי אפילפסיה פעילות מוחית חשמלית ברזולוציה מרחבית וזמנית גבוהה במיוחד. מתוך הקלטות אלו ניתן לחשב סינכרוניזציה בין איזורים מוחיים שונים באמצעות מדדים שונים

כגון שימוש ברכיבים הספקטריים שבסיגנלים. הרזולוציה הגבוהה מאפשרת לבחון את הדינמיקה בזמן של האותות המוחיים והסינכרוניזציה שלהם תוך שימוש בשיטות של למידת מכונה לא מונחית (unsupervised learning).

אחת השאלות המרכזיות כיום בתחום היא כיצד ניתן לזהות ולכמת באופן חישובי מצבי מוח דינמיים מתוך תבניות הפעילות והקישוריות ברצועות התדר השונות שבאותות המוחיים, ובכך להבין טוב יותר כיצד מאורגנת פעילות המוח בזמן מנוחה.

מקורות:

1. Michel, C. M., & Koenig, T. (2018). EEG microstates as a tool for studying the temporal dynamics of whole-brain neuronal networks: A review. *NeuroImage*, 180, 577–593.
2. Hutchison, R. M., Womelsdorf, T., Gati, J. S., Everling, S., & Menon, R. S. (2013). Resting-state networks show dynamic functional connectivity in awake humans and anesthetized macaques. *Human Brain Mapping*, 34(9), 2154–2177.

מטרות הפרויקט

המטרה המרכזית של הפרויקט היא לזהות ולאפיין מצבי מוח דינמיים מתוך נתוני iEEG בזמן מנוחה, על פני רצועות תדר שונות. בפרויקט נגדיר את המצבים המוחיים מתוך נתוני קישוריות וסינכרוניזציה ומתוך נתוני פעילות מקומית (למשל ספקטרוגרמות). הסטודנטים יישמו שיטות של למידת מכונה לא מונחית (כגון K-Means ו-Hidden Markov Models), במטרה לזהות את המצבים החבויים ברצועות התדר השונות, ויכמתו את המאפיינים הזמניים של המצבים האלו (כמו למשל מספר המעברים בין מצבים, זמן שהייה בכל מצב). נרצה להשוות בין התוצאות ברצועות תדר שונות, ולבחון האם קיימים הבדלים עקביים באופי הדינמיקה בין רצועות תדר נמוכות לגבוהות. דרישות: יכולת תכנות בפייתון. קורסים מומלצים: מבוא ללמידת מכונה, מדעי נתונים ביולוגיים, וכל קורס רלוונטי בתחום מערכות מוחיות ומדעי המוח. התוצרים הסופיים של הפרויקט: • חילוף מדדי קישוריות (coherence) ומדדי פעילות (ספקטרוגרמות) ברצועות תדר שונות, מתוך נתוני iEEG. • יישום שיטות למידה לא מונחית (K-Means, HMM) על תבניות הנתונים כדי לזהות מצבים מוחיים. • כימות מאפייני הדינמיקה הזמנית של המצבים שזוהו (למשל מספר המעברים, זמן שהייה, תדירות הופעה). • ניתוח השוואתי בין רצועות תדר שונות ובין מטופלים שונים. • ויזואליזציה של המצבים המוחיים ושל דינמיקת המעברים בזמן.

נושאים נלמדים

- לימוד תאורטי וקריאת ספרות בנושא קישוריות תפקודית דינמית ומצבים מוחיים.
- היכרות עם נתוני iEEG ממטופלי אפילפסיה, ועם שיטות עיבוד אותות מוחיים.
- יישום של אלגוריתמי למידה לא מונחית.
- כתיבת קוד (פייתון) לעיבוד, ניתוח וויזואליזציה של נתוני מוח.

מספר פרויקט: 106 | BioEngineering

ממשק מוח-מחשב מבוסס fNIRS לפענוח מילים

fNIRS-Based Brain-Computer Interface for Decoding Words

פרטי הנחיה

שם המנחה המלא: Moshe Berchansky

דוא"ל המנחה: brachem@biu.ac.il

ראש/ת המעבדה / אחראית/ת אקדמית: Dr. Nisan Ozana

דוא"ל ראש/ת המעבדה: nisan.ozana@biu.ac.il

לרישום יש להזין: מספר פרויקט 106 | שם המנחה המלא: Moshe Berchansky

ראש/ת המעבדה: Dr. Nisan Ozana | הקבלה והשיבוץ מותנים באישור שניהם.

רקע לפרויקט

Functional near-infrared spectroscopy (fNIRS) is a noninvasive, portable neuroimaging technique that measures cortical hemodynamic responses (changes in oxy- and deoxy-hemoglobin) during mental tasks. fNIRS has been used to implement simple brain-computer interfaces (BCIs) for communication. For example, fNIRS-based systems have enabled locked-in patients to answer yes/no questions by performing different mental tasks (e.g. mental arithmetic vs. relaxation), achieving high binary classification accuracies. More recently, researchers have begun exploring semantic decoding: for instance, Rybář et al. (2025) recorded simultaneous EEG and fNIRS while subjects silently named objects (animals vs. tools) and showed that fNIRS signals contain information distinguishing these conceptual categories. However, fNIRS faces challenges: the hemodynamic response is slow and spatially coarse, and signals vary widely across subjects. These limitations mean that decoding arbitrary words (colors, numbers, phrases, etc.) from fNIRS is difficult. Nonetheless, the potential impact is high: a successful fNIRS "speller" could restore communication for patients who cannot use speech or motor systems. In summary, fNIRS offers a safe, affordable way to

monitor brain activity during reading tasks, and prior work suggests it can support at least binary or simple semantic decoding. This project aims to push this toward decoding specific read words.

מטרות הפרויקט

The goal is to develop an fNIRS-based system that predicts which word a person is silently reading. We will focus on a small vocabulary and use state-of-the-art models and methods to classify the fNIRS signals. The expected deliverables are to set up an experimental protocol and dataset of fNIRS recordings labeled with the read words. Then, train an ML model that maps fNIRS time-series to word labels, including an evaluation of performance.

נושאים נלמדים

fNIRS & EEG, Brain Signal Processing, Semantic Decoding, Deep Learning, Brain-Computer Interfaces (BCI)

מספר פרויקט: 114 | BioEngineering

מידול חישובי של הכלייה בדגש על תהליך פגיעה ושיקום

Kidney injury and repair modeling and analysis

פרטי הנחיה

שם המנחה המלא: Hillel Kugler

דוא"ל המנחה: hillelk@biu.ac.il

ראש/ת המעבדה / אחראי/ת אקדמי/ת: Hillel Kugler

דוא"ל ראש/ת המעבדה: hillelk@biu.ac.il

לרישום יש להזין: מספר פרויקט 114 | שם המנחה המלא: Hillel Kugler
ראש/ת המעבדה: Hillel Kugler | הקבלה והשיבוץ מותנים באישור שניהם.

רקע לפרויקט

We will learn how Computational methods can be applied to study critical processes in the Kidney. Gene regulatory networks (GRNs) can be modeled as constrained Abstract Boolean Networks (cABNs) and analyzed with the Reasoning Engine for Interaction Networks (RE:IN), whose underlying reasoning engine is itself SMT-based. We will also evaluate AI methods to help identify new biological data and speed up the methods

- Gerber, Y., et al. "Reasoning About Monotonic Regulation Conditions for Boolean Gene Regulatory Networks: An Algorithmic Approach." IEEE BIBM, 2025, Wuhan, China. DOI: 10.1109/BIBM66473.2025.11356159 <https://ieeexplore.ieee.org/document/11356159>
- Yordanov, B., Dunn, S.J., Gravill, C., Arora, H., Kugler, H., Wintersteiger, C.M. "The Reasoning Engine: A Satisfiability Modulo Theories-Based Framework for Reasoning About Discrete Biological Models." Journal of Computational Biology, 30(9), 2023. <https://pubmed.ncbi.nlm.nih.gov/37733940/>
- Eitan Tannenbaum, Dana Markiewitz, Tomer Kalisky, Hillel Kugler Characterizing Gene Regulatory Network Ensembles in Kidney Injury and Repair
ACM BCB 2025

מטרות הפרויקט

Learn new computational methods to model the kidney

נושאים נלמדים

Computational Modeling of Gene networks
Using and developing state of the art solvers
Understanding how to help the kidney repair after Injury
AI methods in Biology

מספר פרויקט: 2 | ElectroOptics

שימוש בלמידה עמוקה לחיזוי ולשליטה בדינמיקה של רשתות אנושיות

Deep Learning for Predicting and controlling Human Network Dynamics

פרטי הנחיה

שם המנחה המלא: יובל תמיר

דוא"ל המנחה: yuvaltamir23@gmail.com

ראש/ת המעבדה / אחראי/ת אקדמי/ת: פרופסור מוטי פרידמן

דוא"ל ראש/ת המעבדה: moti43@gmail.com

לרישום יש להזין: מספר פרויקט 2 | שם המנחה המלא: יובל תמיר
ראש/ת המעבדה: פרופסור מוטי פרידמן | הקבלה והשיבוץ מותנים באישור שניהם.

רקע לפרויקט

רשתות אנושיות הן מערכות מורכבות שבהן ההתנהגות של כל פרט מושפעת הן מהמצב הפנימי וההיסטוריה האישית שלו, והן מהשפעות הדדיות של פרטים אחרים ברשת. מערכות כאלה מופיעות במגוון רחב של הקשרים, כגון קבלת החלטות קבוצתית, סנכרון בין משתתפים, התפשטות הפרעות ודינמיקה של שיתוף פעולה או תגובה קולקטיבית.

בפרויקט זה נבחן את הדינמיקה של רשתות אנושיות בהשראת מודלים מעולם האופטיקה, ובפרט ממערכות אופטיות מצומדות, שבהן גורמים כגון השהיה, משוב וטופולוגיית הצימוד משפיעים באופן משמעותי על התפתחות המערכת ועל הופעת התנהגות קולקטיבית. רעיונות אלו ניתנים לתרגום גם לרשתות אנושיות, שבהן כל משתתף מגיב לא רק למצבו הקודם, אלא גם להשפעה מושהית של משתתפים אחרים.

הפרויקט מבוסס על נתונים שנאספו בניסוי שנעשה בשיתוף עם נגני כינור מקצועיים, כאשר מבנה הקשרים וההשהיות בין המשתתפים נשלטים באופן ניסיוני, ויכלול תכנון ניסויים נוספים. באמצעות כלים של למידה עמוקה, ובפרט ארכיטקטורות מבוססות מודל Attention, נרצה לנתח את הדינמיקה של המשתתפים ולחזות את התגובה העתידית שלהם על בסיס התנהגות העבר ומבנה הרשת.

מטרות הפרויקט

מטרת הפרויקט היא לפתח וליישם מודל למידה עמוקה לחיזוי הדינמיקה של פרטים ברשת אנושית מצומדת, תוך שימוש בנתונים ניסיוניים ובמבנה הקשרים בין המשתתפים. במסגרת הפרויקט הסטודנטים מודלים של למידה עמוקה, אשר יקבלו כקלט את ההתנהגות הקודמת של המשתתפים ואת טופולוגיית הרשת, וילמדו לחזות את תגובתם העתידית. באמצעות המודל, הפרויקט יבחן כיצד ניתן לזהות דפוסים פנימיים בדינמיקה של הרשת, כיצד הפרעות מתפשטות בין משתתפים, וכיצד נוצרים דפוסי סנכרון וקבלת החלטות קבוצתית. מעבר לחיזוי עצמו, מטרת הפרויקט היא להראות כיצד רעיונות ממערכות אופטיות מצומדות יכולים לשמש בסיס לניתוח ומידול של מערכות התנהגותיות מורכבות.

נושאים נלמדים

במהלך הפרויקט הסטודנטים יחשפו למספר תחומים תאורטיים וחישוביים. תחילה יילמד הרקע הבסיסי של מערכות אופטיות מצומדות, השהיה, משוב וטופולוגיות רשת, תוך התמקדות באנלוגיה בין מערכות אופטיות מצומדות לבין רשתות אנושיות. בנוסף, תילמד הדינמיקה של רשתות מורכבות, כולל סנכרון, התפשטות הפרעות והשפעת מבנה הרשת על התנהגות הפרטים.

בצד החישובי, הפרויקט יכלול עיבוד וניתוח של נתונים ניסיוניים, בניית סט נתונים מתאים לאימון, חלוקה לנתוני אימון ובדיקה, והערכת ביצועי המודל. הסטודנטים ילמדו ויישמו עקרונות בלמידה עמוקה, בדגש על רשתות ניוונים מבוססות Attention, וישתמשו בכלים אלה לצורך חיזוי דינמיקה בזמן. בנוסף, יושם דגש על פרשנות התוצאות, השוואה בין חיזויי המודל לבין הנתונים הניסיוניים, והבנת הקשר בין מבנה הרשת לבין איכות החיזוי.

מספר פרויקט: 63 | ElectroOptics

• שילוב יכולות של בינה מלאכותית ואלגוריתמי לימוד מכונה בחישה ביו רפואית
Incorporation of AI and ML algorithms in remote biomedical sensing

פרטי הנחיה

שם המנחה המלא: יפים ביידרמן
דוא"ל המנחה: yafim.beiderman@biu.ac.il
ראש/ת המעבדה / אחראית/ת אקדמית: זאב זלבסקי
דוא"ל ראש/ת המעבדה: zeev.zalevsky@biu.ac.il

לרישום יש להזין: מספר פרויקט 63 | שם המנחה המלא: יפים ביידרמן
ראש/ת המעבדה: זאב זלבסקי | הקבלה והשיבוץ מותנים באישור שניהם.

רקע לפרויקט

מדובר על טכנולוגיית חישה חדשנית המבוססת על ניתוח שינויים זמניים-מרחביים של תבנית פיזור אור לייזר מרקמה ביולוגית. על בסיס זה ניבחת יכולת חישה של פרמטרים ביו רפואיים מרחוק. תבניות הפיזור הנוצרות עקב התאבכות עצמית של אור הלייזר ניקראות ספקלס. אלו תבניות אקראיות המשתנות בזמן כתלות בתהליכים הזמניים הקורים בתוך הרקמה הביולוגית. במסגרת הפרויקט ניבנה אלגוריתם לימוד מכונה שילמד את מאפייני תבנית הפיזור וידע לקשר אותה לננו-רעידות המתרחשות ברקמה. מתוך ניתוח תבניות הננו-רעידות ניתן לבצע שיערוך של פרמטרים בו רפואיים שונים הכוללים

לחץ דם, מאפיני זרימת דם בכלי דם ועוד. אלגוריתמיקת למידת המכונה שתופעל פה תבוסס על רשתות ניורוליות.

מטרות הפרויקט

לפתח אלגוריתמיקה במטלב, לבדוק אותה בניסוי מעבדתי, לנתח תוצאות ניסוי

נושאים נלמדים

Kalyuzhner, Z., Agdarov, S., Orr, I. et al. Remote photonic detection of human senses using secondary speckle patterns. Sci Rep 12, 519 (2022). <https://doi.org/10.1038/s41598-021-04558-0>

מספר פרויקט: 26 | Nano

מאיץ רשת עצבית טרנארית מבוסס זיכרון Gain-Cell eDRAM

Ternary Neural Network Accelerator in Gain-Cell eDRAM

פרטי הנחיה

שם המנחה המלא: Yuval Harary

דוא"ל המנחה: harariy4@biu.ac.il

ראש/ת המעבדה / אחראי/ת אקדמי/ת: Leonid Yavits

דוא"ל ראש/ת המעבדה: leonid.yavits@biu.ac.il

לרישום יש להזין: מספר פרויקט 26 | שם המנחה המלא: Yuval Harary
ראש/ת המעבדה: Leonid Yavits | הקבלה והשיבוץ מותנים באישור שניהם.

רקע לפרויקט

Deep neural networks on edge devices are limited by the energy cost of moving data between memory and compute, the "von Neumann bottleneck." Processing-in-Memory (PiM) addresses this by computing inside the memory array itself. Existing PiM approaches trade off density, endurance, and accuracy: resistive memory suffers from device variability, SRAM-based PiM has large bitcells, and Binary Neural Networks (BNNs) save area but lose accuracy. Ternary Neural Networks (TNNs) add a zero weight level and recover most of that lost accuracy while staying multiplier-free. Implementing TNNs in memory is hard because a signed ternary product needs both charging and discharging paths on the same bitline, which creates contention. This project builds on Gain-Cell eDRAM (GC-eDRAM), a dense, CMOS-compatible memory technology with decoupled read/write ports, to solve this problem without modifying the memory array itself.

מטרות הפרויקט

To design and evaluate GC-TNN, an in-memory ternary neural network accelerator built on unmodified 3T GC-eDRAM cells. The project decomposes the signed ternary dot product into two non-negative population-count "legs" (positive and negative), resolved by a single analog comparator instead of a calibrated reference voltage. The goal is end-to-end in-memory execution (hidden layers, batch normalization, and output classification) with a compatibility mode for standard BNN inference on the same hardware, calibrated against measurements from a fabricated 16nm FinFET GC-eDRAM test chip.

נושאים נלמדים

Processing-in-Memory (PiM) and Processing-using-Memory architectures

Gain-Cell eDRAM circuit design and operation (3T bitcell, read/write ports, retention/refresh)

Binary and Ternary Neural Network quantization schemes

Analog comparator / sense amplifier design for in-memory sensing

Time-to-digital conversion for signed score readout

Circuit simulation and evaluation using Cadence Virtuoso (post-layout, process variation)

Hardware-software co-design and accelerator benchmarking against SOTA (TiM-DNN, TAIM, CUTIE, XNOR-SRAM)

מספר פרויקט: 31 | Nano

השוואת ביצועים של מימוש אנאלוגי של רשת ניורונים המפועלים ע"י פולסים

Process comparison of the performance of a Spiking Neural network

פרטי הנחיה

שם המנחה המלא: ניל פלדמן

דוא"ל המנחה: neil.d.feldman@gmail.com

ראש/ת המעבדה / אחראי/ת אקדמי/ת: Joseph Shor

דוא"ל ראש/ת המעבדה: Joseph.Shor@biu.ac.il

לרישום יש להזין: מספר פרויקט 31 | שם המנחה המלא: ניל פלדמן
ראש/ת המעבדה: Joseph Shor | הקבלה והשיבוץ מותנים באישור שניהם.

רקע לפרויקט

In recent years Artificial Neural Networks (ANN) have reached maturity, and AI is becoming a technology used everywhere. ChatGPT, Bard and Bing have vast distribution and ANN farms are growing exponentially. The ANN attempts to mimic the human brain as closely as possible to achieve the best possible computing power. As the brain signals are analog and spiky by nature the next step for Artificial Neural Networks is to implement Analog Spiking Neural networks (SNN). The aim of this project is to implement a SNN which is competitive with recent state-of-the-art publications and compare performance in 3 major process nodes: 180nm, 65nm, 28nm.

מטרות הפרויקט

In this project you will compare key design parameters between 3 designs done in 180nm, 65nm and 28nm processes. The design will be based on an implementation done in 28nm and 180nm of a highly compact matrix of Analog Spiking Neurons and Synapses that combined implements a full Analog Spiking Neural network. The Neuron implementation will include the design of a switched-cap integrator and a comparator with a precise programable threshold (see figure below). The Neurons and Synapses will be combined to implement a full 2 layer Analog Spiking Neural network. You will need to learn the theory and then implement the circuit in 65nm CMOS and compare performance to designs implemented already in 28nm and 180nm. The design includes both analog and digital blocks, which will allow you to develop skills in both.

נושאים נלמדים

In this project the student will be exposed to the implementation in 28nm and taking this implementation as a baseline, design a full Analog Spiking Neural Network in 65nm. The student will then compare key performance parameters between the 28nm/65nm and 180nm implementations. The implementation will be done using digital and analog techniques. The schematics will be prepared in Virtuoso and simulated.

מספר פרויקט: 55 | Nano

מיפוי רשתות AI פיזי לחומרה ייעודית

Physical AI Mapping for Custom Hardware

פרטי הנחיה

שם המנחה המלא: דוד שיננזון

דוא"ל המנחה: david.sheinenzon@biu.ac.il

ראש/ת המעבדה / אחראי/ת אקדמי/ת: לאוניד יביץ

דוא"ל ראש/ת המעבדה: leonid.yavits@biu.ac.il

לרישום יש להזין: מספר פרויקט 55 | שם המנחה המלא: דוד שיננזון
ראש/ת המעבדה: לאוניד יביץ | הקבלה והשיבוץ מותנים באישור שניהם.

רקע לפרויקט

רשתות נוירונים מתחום ה-Physical AI דורשות משאבי עיבוד ייחודיים לשם יעילות מרבית. מפותח במעבדה מאיץ חומרה ייעודי לרשתות נוירונים. כדי לאפשר את הרצת הרשתות על גבי השבב, נדרש תהליך המגשר בין המודל ברמת התוכנה לפקודות החומרה ברמת המכונה.

מטרות הפרויקט

מיפוי והרצה של רשתות Physical AI על גבי אמולטור של הצ'יפ הייעודי. העבודה המעשית כוללת: אפיון: ניתוח מבנה הרשת ברמת הפעולה הבודדת (אופי הפעולה, ממדי קלט/פלט ומשקלים). מיפוי: כתיבת קודי Assembly מותאמים אישית לארכיטקטורת השבב. משוב ואופטימיזציה: הרצה באמולטור והעלאת דרישות מקצועיות לצוות החומרה לשיפור התכנון והוספת יכולות.

נושאים נלמדים

ארכיטקטורת מחשבים ומאיצי בינה מלאכותית, תכנות ברמה נמוכה (Assembly) ומבנה פקודות (ISA), תכנון משולב חומרה-תוכנה.

מספר פרויקט: 86 | Nano

התאמה ומיפוי של מודלי Physical AI לסביבת חומרה ייעודית
Mapping and Adaptation of Physical AI Models for Custom Edge Hardware

פרטי הנחיה

שם המנחה המלא: דוד שינזון

דוא"ל המנחה: david.sheinenzon@biu.ac.il

ראש/ת המעבדה / אחראי/ת אקדמי/ת: לאוניד יביץ

דוא"ל ראש/ת המעבדה: leonid.yavits@biu.ac.il

לרישום יש להזין: מספר פרויקט 86 | שם המנחה המלא: דוד שינזון
ראש/ת המעבדה: לאוניד יביץ | הקבלה והשיבוץ מותנים באישור שניהם.

רקע לפרויקט

בשונה ממודלים קלאסיים (כמו זיהוי תמונה סטנדרטי), מודלי Physical AI מציגים מאפייני חישוב מעט שונים שמעניין לבחון ברמת החומרה. מטרת הפרויקט היא לקחת מודל נבחר, לאפיין את הדרישות שלו באופן מעשי, ולבצע תהליך מיפוי (Mapping) ראשוני להרצה על שבב הנמצא בפיתוח במעבדה. העבודה משלבת תרגום של פעולות הרשת לקוד ברמה נמוכה (Assembly) והרצתו באמולטור, במטרה לחוות ולהבין את האתגרים שעולים במפגש שבין המודל הפיזיקלי למגבלות הסיליקון בפועל.

מטרות הפרויקט

יצירת תזרים עבודה (Flow) מעשי שלוקח מודל Physical AI וממפה אותו בהצלחה לסביבת האמולציה של החומרה. הפרויקט יעניק ניסיון פרקטי (Hands-on) בתכנון משולב חומרה-תוכנה (HW/SW Co-Design) ובהבנת ההבדלים בין הרצת מודל בתיאוריה (פיתוח) לבין הרצתו על רכיב חומרה אמיתי.

נושאים נלמדים

ארכיטקטורת מחשבים ממוקדת AI, תכנות שפת סף, תכנון משולב חומרה-תוכנה, ניתוח רשתות נוירונים.

מספר פרויקט: 51 | Communication

עברית: שערור מספר מטרות באמצעות רשת חיישני-מסר מבוססת למידה עמוקה
English: Target Count Estimation Using a Deep Learning Based Sensor-Relay Network

פרטי הנחיה

שם המנחה המלא: יצחק ברגל

דוא"ל המנחה: itsik.bergel@gmail.com

ראש/ת המעבדה / אחראי/ת אקדמי/ת: יצחק ברגל

דוא"ל ראש/ת המעבדה: itsik.bergel@gmail.com

לרישום יש להזין: מספר פרויקט 51 | שם המנחה המלא: יצחק ברגל
ראש/ת המעבדה: יצחק ברגל | הקבלה והשיבוץ מותנים באישור שניהם.

רקע לפרויקט

באפליקציות כמו בקרת קהל או ניטור בעלי חיים בשמורות טבע נדרש להעריך את מספר המטרות הכולל בעזרת רשת חיישנים מבוצרת. כל חיישן מסוגל לזהות ולספור רק את המטרות הנמצאות בתחום הכיסוי המקומי שלו. עקב כיסוי חלקי וחפיפה בין אזורי החישה, מידע מחיישן יחיד או אפילו סכימה של הספירות המקומיות לא יכולים לקבוע את מספר המטרות הכולל. בפרויקט תיבחן רשת של חיישנים-ממסרים, שבה כל צומת משלב חיישן עם ממסר שמגביר את האות הנקלט ומעביר אותו הלאה. הצמתים קולטים את המידע המקומי, משלבים אותו במידע הנקלט, ומעבירים אותו הלאה תוך שימוש משותף באותו ערוץ תקשורת. מבנה זה מאפשר להפחית באופן משמעותי את משאבי הספקטרום הנדרשים להעברת המידע, אך מחייב התמודדות עם עיבוד המידע המצטבר, רעש, הפרעות עצמיות וחפיפה בין אזורי החישה.

מטרות הפרויקט

בפרויקט זה נתייחס לרשת הממסרים כרשת נוירונים, ונפעיל כלי למידת מכונה לצורך אופטימיזציה של כל אחד מהחיישנים-ממסרים ואופטימיזציה רשתית לצורך שערור המספר הכולל של מטרות בשטח. במסגרת הפרויקט ייבנה מודל מתמטי של תהליך החישה ושל ערוץ התקשורת ויפותח אלגוריתם מבוסס למידה עמוקה המפיק אומדן גלובלי של מספר המטרות. ביצועי השיטה ייבחנו באמצעות סימולציות עבור פריסות שונות של חיישנים ומטרות, רמות שונות של רעש ודרגות שונות של חפיפה בין החיישנים.

נושאים נלמדים

- חישה מבוזרת ומיזוג מידע מרשת חיישנים
- רשתות ממסר מסוג Amplify-and-Forward
- יישום שיטות למידה עמוקה, כולל בניית רשתות, אימון, מדידת ביצועים ואופטימיזציה

מספר פרויקט: 52 | Communication

צבירת מידע ממכשירי IoT באמצעות למידה עמוקה ורשת ממסרים לא-לינאריים
Information Aggregation from IoT Devices Using Deep Learning and a Nonlinear Relay Network

פרטי הנחיה

שם המנחה המלא: יצחק ברגל
דוא"ל המנחה: itsik.bergel@biu.ac.il
ראש/ת המעבדה / אחראי/ת אקדמי/ת: יצחק ברגל
דוא"ל ראש/ת המעבדה: itsik.bergel@biu.ac.il

לרישום יש להזין: מספר פרויקט 52 | שם המנחה המלא: יצחק ברגל
ראש/ת המעבדה: יצחק ברגל | הקבלה והשיבוץ מותנים באישור שניהם.

רקע לפרויקט

ברשתות IoT הכוללות מספר גדול של מכשירים, לכל מכשיר יש כמות קטנה של מידע, אך נדרש לאסוף מידע ממכשירים רבים תוך שימוש יעיל במשאבי התקשורת. בשיטות מסורתיות, כל מכשיר משדר במשאב זמן-תדר נפרד, ולכן דרישות רוחב הפס גבוהות. בפרויקט זה תיבחן ארכיטקטורה שבה כל מכשירי ה-IoT משדרים בו זמנית באותו משאב זמן-תדר. כל אחד משדר ביט אחד, ורשת של ממסרים משלבת את האותות המתקבלים ומעבירה אותם לעבר מקלט מרכזי. באמצעות עיבוד מתאים בממסרים, ניתן לאגד את המידע של מספר רב של מכשירים ולאפשר למקלט לשחזר את המידע של כולם בו-זמנית. גישה זו יכולה להפחית משמעותית את משאבי הזמן והספקטרום הנדרשים, אך יוצרת אתגרים הנובעים מעיבוד לא-לינארי של אותות, רעש מצטבר, והפרעות בין המכשירים.

מטרות הפרויקט

בפרויקט זה נתייחס לרשת הממסרים כרשת נוירונים, ונפעיל כלי למידת מכונה לצורך אופטימיזציה רשתית של העברת המידע המצרפי למקלט. במסגרת הפרויקט ייבנה מודל מתמטי המאגד את השידור מהמכשירים, המעבר בערוץ, הפעולה הלא לינארית של הממסרים והעיבוד במקלט הסופי, ויפותח אלגוריתם למידה עמוקה לתכנון פעולות ההגבר והקליטה כך שהמקלט יוכל לשחזר את המידע מכל המכשירים. ביצועי השיטה ייבחנו באמצעות סימולציות עבור מספרים שונים של מכשירים וממסרים, טופולוגיות רשת שונות, ורמות שונות של רעש.

נושאים נלמדים

- תקשורת מרובת משתמשים ברשתות IoT
- רשתות ממסר מסוג Amplify-and-Forward
- מודלים של ערוצי תקשורת, רעש ודעיכה
- יישום שיטות למידה עמוקה, כולל בניית רשתות, אימון, מדידת ביצועים ואופטימיזציה