

ניטור אקוסטי של פעילות זחל הלקטית לצורך

תזמון הדברתו / ויקי סורוקר

שם החוקר/ת הראשי/ת: ד"ר ויקטוריה סורוקר

שותפים: אמוץ חצרוני, עמוס מזרח, אריאלה ניב

מסגרת אירגונית (מנהל המחקר החקלאי, כל הארץ).

מטרה כללית

לשכלל את שיטת ניטור הזחלים תוך פיתוח שיטה אקוסטית לזיהוי ההלקטים הנגועים בלי לפגוע בשלמותם.

רקע והצדקה

הלקטית וורודה היא אחד ממזיקי הכותנה הנפוצים והקשים בארץ ובארצות העולם. מזיק זה תוקף, בעיקר, צמחים ממשפחת החלמיתיים עם עדיפות לכותנה. המזיק פוגע בהלקטים ובזרעים שבתוכם וגם בכפתורים צעירים. הנזק להלקטים הוא משמעותי מבחינה כלכלית ונגיעות קשה יכולה להוביל לאובדן של היבול כולו.

זחל ההלקטית בוקע מהביצה בגודל של 1 מ"מ, חודר להלקט תוך שעותיי מבקיעתו, ואינו משאיר סימנים בולטים על פני ההלקט. הזחלים מוגנים בתוך אברי הצמח, ועובדה זו מורידה את זמינותם להדברה הן על ידי האויבים הטבעיים והן על ידי תכשירי הדברה כימיים (Ingram, 1994).

קיימת בעיה חמורה בתזמון ההדברה של ההלקטית הורודה. הריסוסים מכוונים בעיקר נגד בוגרים או הזחלים בעת בקיעתם שאותם קשה לנטר בצורה מדויקת. בעיה נוספת היא פיתוח עמידות לתכשירי ההדברה. הבעיה קיימת לגבי כל המזיקים וכיום מופנה המאמץ למציאת דרכים לעיכוב ולהאטת התהליך.

בהתאם, מדיניות השימוש בתכשירי ההדברה בכותנה מבוססת על העיקרון של טיפול באוכלוסייה ולא בפרט, כשיחידת ההתייחסות הינה דור של חרקים מזיקים. הרעיון המרכזי הוא חשיפת דור אחד של המזיק, בכל שנה, לקבוצת תכשירי הדברה מסוימת - וכך לאפשר לאוכלוסייתו לאבד, במשך שאר השנה, את תכונות העמידות שנרכשו בזמן החשיפה המוגבל לקבוצה הכימית המסוימת. בשנים האחרונות ירד מספר הריסוסים בכותנה - בממוצע ארצי - מכ-16 ריסוסים לכ-5 ריסוסים.

לממשק הלקטית תקין חשוב לשמור את הנגיעות מתחת לרמות הנזק בעונת הגידול, וכן לצמצם את האוכלוסייה הנכנסת לדיאפאוזת. אנחנו מאמינים שביסוד ממשק יעיל עומד ניטור אמין של המזיק שעל פיו ניתן לקבוע רמות סף ולהגיע לתזמון הדברה יעיל. קיימות בעולם מספר שיטות לניטור האוכלוסיות של ההלקטית: ניטור הלקטים נגועים בזחלים, ניטור ביצים על הלקטים, וניטור הזכרים הבוגרים באמצעות מלכודות פרומונים. למרות ששיטה ניטור הזכרים באמצעות מלכודות פרומון הינה נוחה ליישום והביאה

לשיפור רב בשנות השישים והשבעים ביחס לריסוסים פרופילקטיים, היא נותנת בעיקרה אומדן איכותי, עבודה רבה הושקעה בחיפוש מתאם בין הלכידות לנגיעות - אך מתאם כזה לא נמצא ובאף מדינה בעולם לא משתמשים בשיטה זאת לניטור. סיבה נוספת נגד ישום שיטה זאת לניטור היא התבססותה של הדברת הלקטית הוורודה בשיטת "בלבול" בפרומונים. השנה יושמה שיטת ה"בלבול", בארץ, בכ-100% משטחי הכותנה.

השיטה הנפוצה ביותר בעולם, ולמעשה משמשת לניטור ולקבלת החלטות הדברה בכל הארצות מגדלות הכותנה, (חוץ מאשר בישראל) היא שיטת ניטור הזחלים באמצעות פתיחת הלקטים. שיטה זו מאוחרת מבחינת הממשק, אך ניתן לשפרה. בשיטת ניטור זו בודקים הלקטים לנוכחות בקיעות ביצים וזחלים צעירים, מתוך הנחה שהאילוח נעשה בצורה מחזורית ואם "תופסים" את גל האילוח מוקדם - עדיין אפשר לפגוע במרבית אוכלוסיית המזיק שהיא עדיין מחוץ להלקט (עשים וביצים). בשיטה זו נותנים בד"כ ריסוס נוסף לאחר כשבוע לשם "קטיעת" גל ההטלה. ניתן ומומלץ להשתמש בשיטת ניטור זו בישראל גם בתנאי "בלבול" וגם ללא "בלבול", כאמצעי משלים לקביעת רמות הנגיעות בשדה. המגרעות העיקריות של שיטה זו הן השקעת הזמן הדרושה, הצורך במיומנות גבוהה בזיהוי הזחלים הקטנים והסיכון לאחור בעיתוי הגילוי בזמן.

אנו משערים שניתן לשכלל את שיטת ניטור הזחלים תוך ניצול קולות הכרסום שלהם, ללא צורך בפגיעת ההלקט. השיטה המוצעת מתבססת על זיהוי קולות הכרסום של הזחלים. מכשיר שפותח בארה"ב (Hickling et al., 1994) היה אמור לאפשר זיהוי קולות הכרסום של זחלים. לצערנו מכשיר זה קולט רעשי רקע רבים ואינו מאפשר קבלת אות ברור. בעבודתינו אנו משתמשים במכשיר אחר שפותח לגילוי מזיקי איסום (Larven Lausher, NIR service W. Weinard). מכשיר זה רגיש מאד לקולות חרקים. המטרה הכללית של המחקר היא לשכלל את שיטת ניטור הזחלים תוך פיתוח שיטה אקוסטית לזיהוי ההלקטים הנגועים, בלי לפגוע בשלמותם. בשנתיים הראשונות של המחקר נערכו הקלטות פעילות זחלי ההלקטית. במהלך המחקר אופוין המיקום של זחלים בתוך ההלקט, בדרגות השונות ובתנאי טמפרטורה שונים. מניסויים ופיתוח מודל סטטיסטי לניתוח קולות כרסום ההלקטית. פיתוח מודל סטטיסטי לזיהוי תבנית במרחב רב מימדי המורכב משני רכיבים עיקריים: למידה וניתוח קולות כרסום ורעשי רקע בזמן אמת.

בשנה הנוכחית: התרכזנו בשני נושאים עיקריים א. איתור זמני ניטור אקוסטי אופטימלי, ב. פיתוח מודל לזיהוי תבנית קול במרחב רב מימד לעיבוד offline ובזמן אמיתי on line.

מהלך המחקר

מציאת זמני פעילות אקוסטית מרבית של הזחלים.

לשם כך עקבנו אחרי פעילות זחל בודד באמצעים אקוסטיים. על כל הלקט פימה בן כשבועיים הודבק זחל שזה עתה בקע. ההלקטים נשמרו באינקובאטור בטמפרטורה קבועה של 28 מעלות וללא תאורה. ביצי ההלקטית

נתקבלו מגידול ההלקטית שבמעבדתו של ד"ר רמי הורוביץ בגילת. ההלקטים נאספו מחממה של שוקי סרנגה בפקולטה לחקלאות, רחובות.

פעילות הזחל בהלקט נרשמה בשתי שיטות: א. רישום ידני של אירועי פעילות. ב. רישום רציף של אירועי פעילות למחשב, באמצעות תוכנה ייחודית שפותחה על ידי משתתפי הפרויקט, בסביבת Matlab. לצורך זה נבנה תא "אקוסטי" שבודד על ידי שכבה של צמר סלעים והוצב בתוך האינקובאטור דלעיל (

איור 1).



איור 1: תא אקוסטי להקלטות פעילות זחלים

רישום ידני של פעילות זחלים

רישום פעילות המפעיל שמע מגבר ובמכשיר שפותח



לצורך "ידני" של הזחל צויד במערכת (מיקרופון, ואזניות) רישום

במיוחד לצורך הפרויקט הנוכחי. מכשיר הרישום הורכב מאוגר נתונים שתוכנת לקלוט לחיצות של המפעיל על כפתורי הבקרה ולרשום את עיתוי הלחיצה בנוסף למצב כפתורי ההפעלה האחרים. כל לחיצה על אחד משני כפתורי הרישום רשמה לקובץ הנתונים את עיתוי הלחיצה: יום, שעה, דקה ושנייה. עקב התעייפות המפעיל האנושי הופעלה המערכת לפרקי זמן קצרים בכל פעם, 10 עד 20 דקות למחזור. מעבר לכך לא ניתן היה לסמוך על ערנות המפעיל. המפעיל הקשיב לקולות באוזניה ובכל פעם שזיהה פעילות של זחל לחץ על הכפתור המתאים. התוצאה קובץ רישום אירועים (log file) בו כל שורה מציינת אירוע שזוהה כפעילות זחל.

איור 2: מערכת לאיסוף "ידני" של נתוני פעילות

רישום רציף של אירועי פעילות

המגבלות האנושיות והצורך במשכי דגימה ארוכים יותר הוביל לפיתוח מערכת רישום אירועים אוטומטית. מערכת זאת פותחה על בסיס תכנת Matlab. מוצא המיקרופון חובר לכרטיס הקול של המחשב. בזמן הפעלת התכנה, בהיקלט קול שחרג מערך סף שנקבע, נרשם אירוע לקובץ שמבנהו דומה לקובץ ברישום הידני. פיתוח מודל לזיהוי תבנית קול במרחב רב מימד לעיבוד offline ובזמן אמיתי on line.

ניטור אקוסטי של הזחל היא בעיה בתחום של עיבוד אותות ולמידה. קיימות מספר גישות קלאסיות לפתרון בעיות מסוג זה. באופן כללי המשותף לכולן הוא מנגנון הזיהוי של האותות החשודים ומנגנון הלמידה שיוצר מודל לזיהוי אותות הנוצרים ע"י זחל. שיטות אפשריות הן מודלים סטטיסטיים, מודל ה-KNN, רשת עצבית, עץ החלטה או רשימת החלטה. בשנה זאת התמקדנו בבחינת רשת עצבית.

אחת הסיבות לבחירה ברשת עצבית היא הפשטות היחסית של העברת מנגנון הלמידה שנוצר באופן חד פעמי במעבדה לרכיב יעודי עבור הרצת רשתות עצביות. ידוע לנו על מספר רכיבים כאלו בשוק.

לצורך זיהוי פעיות הזחלים פיתחנו מספר כלים בסביבת העבודה של (Matlab (Mathworks, ver 6.5 Neural Networks Toolbox (R13, Natick, MA, USA) ובשימוש ב- הפיתוח כלל כלים אוטומטיים לסריקת קבצי ההקלטה, סוג שנעשה ע"י מומחה וחילוץ קבוצות מאפיינים שונות מהאותות החשודים שאותרו בהקלטה.

לצורך הטיפול באותות פותח אלגוריתם למציאת אותות חשודים. האלגוריתם חיפש במקטעים קצרים שינויים יחסיים בעוצמות המתח. נבחנו מספר שיטות לאפיון האותות. כל השיטות מבוססות על אפיון וניתוח תדרים. התדרים נמדדו ע"י FFT בשיטה מקובלת. משפחת השיטות שהניבו את התוצאות הטובות ביותר מתארים היסטוגרמה של התדרים ברזולוציה של 100 הרץ בטווח בין 500 הרץ ל-5500 הרץ, בטווחים אלו זיהינו פעילות ספקטראלית של הזחל. נבחנו צפיפויות שונות אך צפיפות גבוהה גרמה לאלגוריתם למידה לרוץ בזמן ארוך מאוד ללא שיפור בזיהוי וצפיפויות נמוכות הניבו תוצאות פחות מדויקות. הרחבת טווח התדרים לא תרמה לאיכות הזיהוי.

רשת עצבית הינה שיטה לייצוג פונקציה על ידי שימוש במספר יחידות חישוב פשוטות המקושרות בצורת גרף. רשת עצבית מורכבת ממספר יחידות חישוב אשר מקושרות ביניהן על ידי משקולות המתעדכנים במהלך תהליך הלמידה. חלק מהיחידות מקושרות לסביבה החיצונית, והן מהוות את הקלט והפלט של הרשת. כל יחידה מבצעת חישוב מקומי על סמך הקלט שהיא מקבלת, ומוציאה תוצאות החישוב כפלט אשר מתקבל כקלט ביחידה הבאה כל יחידות החישוב עובדות במקביל ללא צורך בבקרה מרכזית. ישנו מגוון סוגים של מבני רשתות, כאשר לכל אחת מהן מאפיינים שונים. בדרך כלל הרשת בנויה ממספר שכבות. ההבחנה העיקרית נעשית בין רשת מסוג Feed-forward לבין רשת מסוג Recurrent. בסוג הרשת הראשון הקשרים הם חד-כיווניים בלבד ואין מעגלים (גרף אציקלי מכוון), ולכן היא הרשת הפשוטה ביותר לניתוח. ב-Layered feed-forward network כל יחידה מקושרת ליחידה ברמה הבאה. אין קשרים בין יחידות באותה רמה, או לרמה הקודמת ואין אפשרות לדלג על רמות. בסוג הרשת השני קשרים יכולים להיות בכל צורה שהיא לעבודה זאת נבחרה רשת עצבית מסוג Feed Forward Multiple Layer. יתרונה בלימוד מודרך. מבנה הנתונים שלפנינו מאפשר למידה מודרכת לאחר סיווג את האותות החשודים ע"י שמיעה (לימוד בסיוע מומחה).

את מערך המאפיינים (372 דוגמאות) הזנו למספר רב של רשתות עצביות ובחנו את אופן ההתכנסות שלהן, והתמודדותן מול אותות חדשים)

טבלה 1).

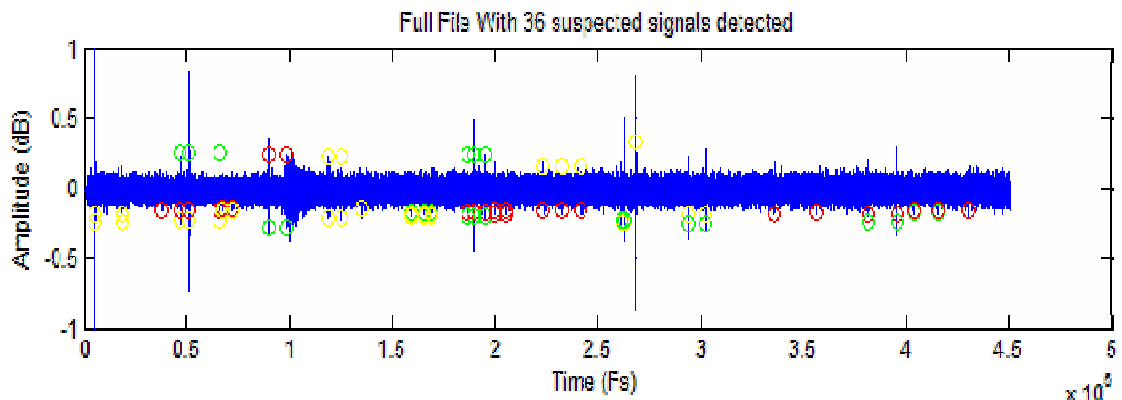
נבחנו שתי שיטות הצגת נתונים לרשת העצבית: Linear Buckets ו-Top N Frequencies. קובץ הלימוד כלל 372 דוגמאות. הזנת נתונים בפורמט של Linear Buckets זכה לאחוזי ההצלחה הגבוהים ביותר. בהתאם לכך נבחנה התכנסות הרשת בתלות בפרמטרי הרשת (מספר התאים ותחומי התדרים). לאחר שלב הלימוד נבחנו מספר רשתות על קטעי קול חדשים, שלא נכללו בשלב הלימוד (טבלה 2). דוגמא לביצועי הרשת על רקע האות המקורי מוצגת באיור 3.

טבלה 1: סוגי הרשתות שונות שנבחנו לצורך זיהוי קולות

Goal	Learning Rate	Epoch	Layer Initialization Function	Learning Function	Transfer Function	Performance Function	Training Function	מספר הרשת
0.001	0.1	1000	initnw	learnp	tansig	MSE	TRAINgdm	1
0.001	0.1	1000	initnw	learnp	logsig	MSE	TRAINgdm	2
0.001	0.1	1000	initnw	learnp	tribas	MSE	TRAINgdm	3
0.001	0.1	10000	initnw	learnp	tribas	MSE	TRAINgdm	4
0.001	0.1	1000	initnw	learnk	tribas	MSE	TRAINcgp	5
0.001	0.1	1000	initnw	learnpd	Poslin	MSE	TRAINr	6
0.001	0.3	1000	initnw	learnwh	tribas	MSE	TRAINscg	7
0.001	0.2	5000	initwb	Learnlv1	radbas	MSE	TRAINgdm	8
0.001	0.1	600	initnw	learnqdm	satlin	MSE	TRAINcgb	9
0.0001	0.1	10000	initnw	learnp	tribas	MSE	TRAINbfg	10

טבלה 2: בדיקת מודל החלטות הרשת על נתונים שלא נלמדו. טבלת אחוזים המראה את אחוזי הצלחת זיהוי הרשתות, את אחוז הטעויות של הרשתות ואת אחוז חוסר ההחלטה שלהן.

מספר הרשת	אחוז גילוי ביחס למומחה	אחוז טעויות ביחס למומחה	אחוז חוסר הכרעה
3	64%	0%	36%
5	21%	42%	37%
6	42%	48%	10%
7	36%	19%	45%
8	53%	42%	5%
10	3%	17%	80%



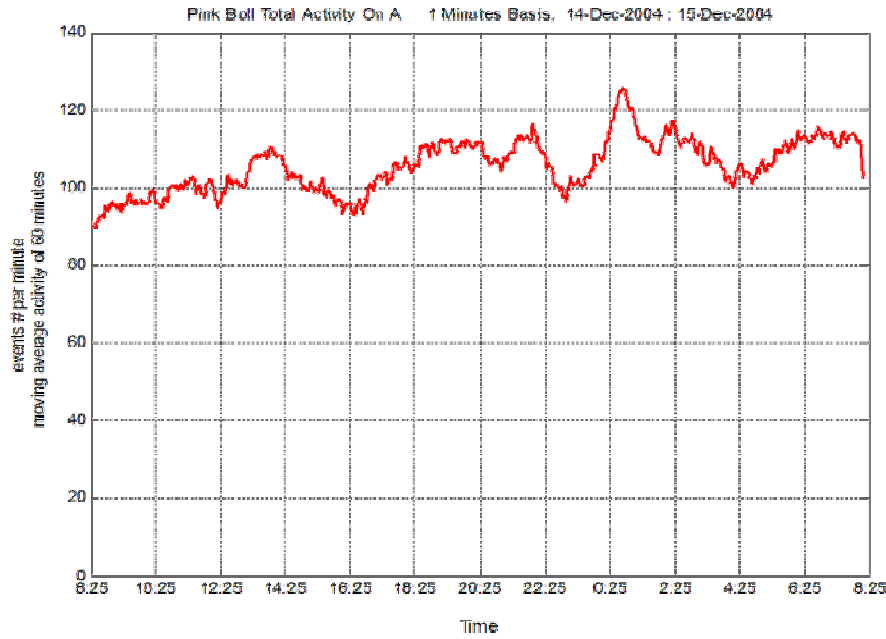
איור 3 התרשים מראה עבור אילו אותות התקבלה איזו החלטה. מקרא: כחול - קובץ הקול, אדום - רעש, צהוב - אין הכרעה, ירוק - יש פעילות זחל.

תוצאות

מציאת זמני פעילות

בשתי השיטות של רישום הפעילות (ידני ואוטומטי) מתקבלת תמונה של פעילות אכילה של החרק בכל שעות היממה. יחד עם זאת נראה שפעילות החרק איננה רציפה במהלך היממה, בקצב ובעוצמה בשלב הזה נרשמת פעילות כמעט רציפה (לדוגמא

איור 4). מספר אירועי הפעילות כשהזחל צעיר נמוך, ויש זמנים בהם הזחל אינו פעיל כלל. עם התפתחות הזחל עוצמת פעילותו עולה. הפעילות הרבה ביותר מתקבלת כאשר הזחל מפלס את דרכו מעומק ההלקט לעבר הדופן, תוך יציאתו להתגלמות. כמעט ולא נמצאו זמנים של חוסר פעילות מוחלט.



איור 4 : מספר אירועי פעילות של זחל הלקט ורוד בדקה במהלך של כיממה.

זיהוי פעילות על ידי רשת עצבית

נקבע מודל Linear Buckets כמתאים לצורך הזנת נתוני הקול לתוך הרשת העצבית. תוצאות ההתכנסות נמצא ערך זיהוי חיובי של 64%. יש לשים לב כי הזיהוי שנמצא הוא זיהוי ודאי.

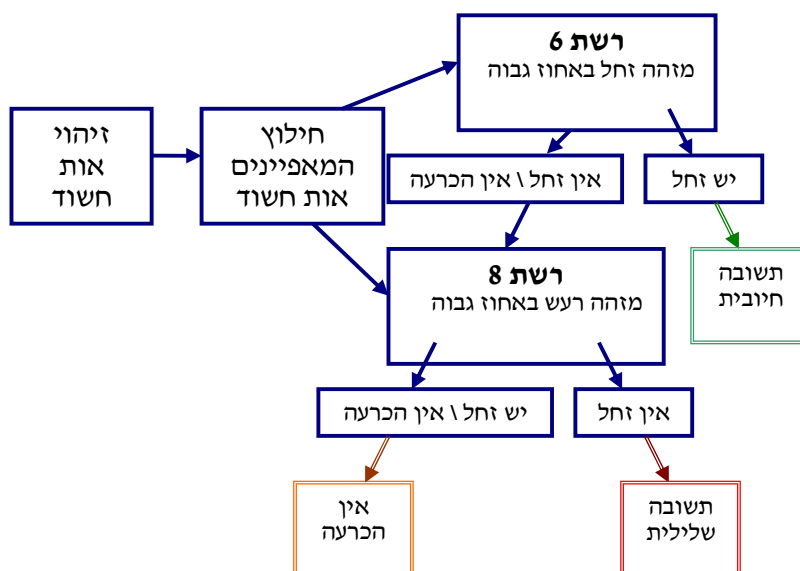
מסקנות

תוצאות הלמידה של הרשת היו מעודדות, רשתות מסוימות שחקרנו למדו את מאגר הדוגמאות עם אחוזי הצלחה גבוהים למדי. תוצאות זיהוי האותות בקבצי הקלטה חדשים ע"י המודל שפותח היו טובות מעט פחות מאיכות הלמידה. הרשת הטובה ביותר שפיתחנו סווגה 64% מהאותות נכון בדיוק של 100%. הרשת נמנעה מלסווג לא נכון אותות לא ברורים, והכריזה על שאר האותות כחסרי סוג. תוצאות רשת עצבית זו מספקות זאת מכיוון שזחל פעיל מפיק מספר אותות אקוסטיים בדקה. לפיכך האזנה בפרק זמן של מספר דקות תיתן הכרעה בהסתברות גבוהה. את אמינות וודאות הזיהוי ניתן להעלות באופן משמעותי על ידי שילוב של מספר רשתות עצביות כפי שמוצג ב

איור 5.

ברישום אותות פעילות הזחל לא נמצאה תבנית ברורה של מחזורי פעילות לאורך היממה ולא נמצאו פרקי זמן ממושכים של אי פעילות. ממצאים אלו מצביעה על סבירות גבוהה לזיהוי פעילות זחל בהלקט בדיגום הלקטים אקראי ולפרקי זמן קצרים.

בימים אלו אנו ממשיכים בחקר השונות בקולות הזחל בגדלים שונים ולבחירת שיטת זיהוי תבנית על בסיס תדר. כל אלה יתרמו לפיתוח מכשיר לזיהוי אקוסטי של הלקטית.



איור 5: עץ החלטה יעיל שמנצל יתרון שתי רשתות (רשתות 6 ו-8)

תודות

אשר לוי על פיתוח מערכת הדגימה הידנית וליווי ההיבטים הטכניים; טלי אזמנוב על פיתוח מערכת ניתוח הנתונים; יואל פינחס ורז עזיז על פיתוח מערכת הרשת העיצבית, פיתוח תכנות Matlab והיבטם אקוסטיים שונים; יוסף גרינשפון על התמיכה והפיתוחים האלקטרוניים, שלומית לבסקי, שוקי סרנגה, רמי הורוביץ

(+עובדי המעבדה)