

גיליון מספר 206 | אוגוסט 2025, תשפ"ה

שמורת טבע

עלון מורי הביולוגיה

בינה מלאכותית



מכון
והצמח
למדע

WEIZMANN
INSTITUTE
OF SCIENCE

המרכז הארצי
למורי הביולוגיה



מינהלת מל"מ
המרכז הישראלי לחינוך מדעי-טכנולוגי
ע"ש עמוס דה-שליט



מדינת ישראל
משרד החינוך
המזכירות הפדגוגית
אגף א' לסדעים
הפיקוח על הוראת הביולוגיה
הפיקוח על הוראת מדעי הסביבה



שלום לכולכם,

בינה מלאכותית משנה את העולם, ופותחת אפשרויות חדשות לתחומים רבים כל כך. לביולוגיה שמורה פינה חמה בתחום, שכן מדעי המוח והקוגניציה הם השראה לפיתוחים של בינה מלאכותית ואף נתרמים ממנה.

בגיליון זה ריכזנו בעבורכם תכנים הקשורים לתרומה ההדדית של מדעי המוח ומדעי המחשב בהבנת תהליכי למידה ובכלל זה ראיון עם מדען החוקר את פעילות המוח בעזרת כלי בינה מלאכותית. הקשר להוראה מתבטא במאמר העוסק באמון שבני אדם נותנים בכלי בינה מלאכותית; במאמר העוסק בבינה מלאכותית ככלי הערכה של תשובות תלמידים לשאלות פתוחות; ובפעילויות לתלמידים המשלבות בינה מלאכותית.

קריאה מהנה,

גילת בריל

עורכת העלון

וצוות המרכז למורי הביולוגיה

עורכת: ד"ר גילת בריל

ייעוץ אקדמי: פרופ' ענת ירדן

עימוד ועיצוב גרפי: מור מוריה-שיפוני

עריכת לשון: ענבל גיל

מנהל הפרויקט: ד"ר אוהד לבקוביץ

תמונת השער: תאי עצב במוח יוצרים רשתות, קבוצות של תאי עצב המקושרים ביניהם ולרוב מופעלים (או מעוכבים) יחד. העובדה שכל תא עצב ברשת מקושר לתאי עצב רבים אחרים יוצרת מורכבות רבה. האופן שבו רשתות תאי עצב במוח פועלות ולומדות הוא מקור השראה לפיתוח ובנייה של רשתות עצביות מלאכותיות המורכבות ממחשבים ומופעלות באמצעות אלגוריתמים. בתמונה נראים תאי עצב (בירוק) המרכיבים את הקורטקס במוח של מכרסם. התאים עברו תהליך של צביעה ייחודית המאפשרת להבחין בהם מבעד למיקרוסקופ.

אין לשכפל, להעתיק, לצלם, להקליט, לתרגם, לאחסן במאגר מידע, לשדר או לקלוט בכל דרך או אמצעי אלקטרוני, אופטי, מכני, או אחר, כל חלק שהוא מהחומר שבספר זה. שימוש מסחרי מכל סוג שהוא בחומר הכלול בספר זה אסור בהחלט, אלא ברשות מפורשת בכתב מהמוציא לאור.

הפרויקט מבוצע על ידי המחלקה להוראת המדעים במכון ויצמן למדע עבור משרד החינוך במסגרת מכרז מס' 22/11.2020: הקמה והפעלה של מרכזי המורים ארציים במקצועות הבאים: מדעים, טכנולוגיה ומתמטיקה.

© כל הזכויות שמורות למשרד החינוך





מורות ומורי ביולוגיה יקרים,

פרסום עלון זה מאפשר הזדמנות נוספת להודות לכל מי שעוסקים בהוראת הביולוגיה. לכן ולכם, ללבורנטיות ולבורנטים, לצוותי ההדרכה, מרכז המורים לביולוגיה במכון ויצמן, מרכז המעבדות באוניברסיטת בר אילן, לחוקרות וחוקרי הוראת המדעים, למכשירות ומכשירי הסטודנטים לתעודת הוראה, לחברות וחברי ועדת המקצוע ולגמלאיות שממשיכות לתרום מניסיוןן בשמחה. תרומתכם המקצועית והמסורה היא הבסיס להצלחה של קהילה מורי הביולוגיה.

לצערנו לא נפגשנו פנים אל פנים בכנס המורים האחרון בשל השילים האירנים. הפגנתם חוסן מרשים בכך שהמשכתם ללוות את התלמידים גם במערכה "עם כלביא" והשתתפתם בכנס המקוון גם בזמן מתקפת טילים. משמע עלוני שמורת טבע האחרונים שעסקו בחוסן, תרמו לביסוס החוסן. בעלון האחרון שולבה גם פעילות בעזרת בינה מלאכותית ועלון זה עוסק כולו, איך לא, בבינה המלאכותית שהפכה להיות טבעית בשגרת הפעילות שלנו.

פניתי אל ה-ChatGPT בבקשה לסייע לי בניסוח ברכה לכבוד יציאת גיליון שמורת טבע זה. הגדרתי את קהל היעד, הגבלתי לארבע שורות והוספתי עוד כמה בקשות. זו התוצאה:

בברכת פתיחת גיליון חדש של עלון מורי הביולוגיה, אני רוצה להדגיש את החשיבות העצומה של השימוש בבינה מלאכותית בעידן המודרני. הכלים והטכנולוגיות החדשות הללו מספקים לנו הזדמנויות בלתי נגמרות לחדש את הדרך בה אנו חוקרים את הביולוגיה, להבין תהליכים מורכבים ולפתח פתרונות מתקדמים לאתגרים רפואיים וסביבתיים. אני מזמינה אתכם להעמיק ולהתנסות בידע החדש שיביא עימו הגיליון, ולראות כיצד ניתן לשלבו בהוראתנו ובמחקרנו.

ביקשתי להפוך את הכתוב לשיר בחרוזים (ובתוצר עשיתי שינויים קלים):

למורות ומורי הביולוגיה היקרים,
בעלון חדש נגלה עולמות מרגשים.
בינה מלאכותית היא פתח של אפשרויות,
מעצבת מחקר, מניעה התפתחויות.
בביולוגיה נוכל לגלות,
תהליכים עמוקים, חידושים שלא ידענו קוד ופיצוח סודות.

ואכן, הכל נכון... ובעלון זה תוכלו לקרוא על שירת הכנרית, השראה הדדית, המאפיינים של יחסי האמון בין אדם למכונה, סיוע בכתביה במסגרת הביוחקר והערכה של שאלות פתוחות.

העיסוק בבינה המלאכותית לא החל עם עלון זה... כבר לפני שנתיים התחלנו בהשתלמויות וסדנאות בתחום למורות ומורי הביולוגיה. נפתחה קבוצת וואטסאפ וקהילה למשתמשים "כבדים" תתחיל לפעול השנה. מי שעדיין לא נעזרים בבינה המלאכותית, מוזמנים לקפוץ למים (או יותר נכון למרחבי הרשת), עם או בלי השתלמות, בעזרת פרקטיקות שהוצגו בפורטל עובדי הוראה, במרחב הפדגוגי וגם בעזרת הכתבות שבגיליון זה.

יחד עם זאת יש צורך להיזהר. השימוש בבינה המלאכותית עלול למכר. כמו כן, יש להפעיל חשיבה ביקורתית ולוודא שלא שולבו המצאות והפתעות בתוצרים המוצעים על ידי הבינה. בינה מלאכותית אינה חזות הכל. עוד בימים אלו, לקראת תחילת שנת הלימודים תשפ"ו, מי שעדיין לא מכירים את קורסי ההכנה לבגרות בביולוגיה בקמפוס IL בעברית ובערבית: "התא" "אקולוגיה" ו"גוף האדם", שיכולים לשמש להוראה בכל אחת משכבות הגיל ואת המשאבים השונים באתר של מרכז המורים לביולוגיה, אתר מרכז המעבדות ואתר מפמ"ר, זה הזמן להכיר. כמו כן חוזר מפמ"ר לתשפ"ו פורסם בשולחן המפמ"ר ובקרוב יפורסמו ערוצי התקשורת השונים עם צוות ההדרכה לשנת תשפ"ו.

הבינה המלאכותית חשובה אך אתן ואתם המורים לביולוגיה, חשובים עוד יותר. בתקופה זו, בה אנו מתמודדים עם אתגרים רבים, חשוב לזכור ולנצל את כוחנו להשפיע על הדורות הבאים, עם הבינה המלאכותית ובלעדיה, בבינה.

מאחלת קיץ פורה ממלא מצברים, בתקווה לבשורות טובות ושנחזור מלאי אנרגיות טובות לשנת הלימודים.

אירית
ד"ר אירית שדה, מפמ"ר ביולוגיה

תוכן העניינים

שירת קנריות היא מודל עשיר ומורכב ולכן אנו נעזרים בבינה מלאכותית ראיון עם ד"ר ירדן כהן

5



השראה הדדית
תהליכי למידה במוח וברשתות עצביות מלאכותיות

11



מהפכת ה-AI בכיתת הביולוגיה
שילוב בינה מלאכותית בתהליך הביוחקר

19



אפשר לסמוך עליך?
גורמים המשפיעים על אמון בכלי בינה מלאכותית

23



מותר להוציא ניידים
אתרים וקישורים בנושא שיקום וחוסן בטבע

29



פיתוח כלי להערכה אוטומטית של תשובות לשאלות פתוחות
שילוב עקרונות פדגוגיים עם למידת מכונה

31





"שירת קנריות היא מודל עשיר ומורכב ולכן אנחנו נעזרים בכלי בינה מלאכותית"

ד"ר ירדן כהן חוקר את הפעילות המוחית של קנריות כשהן יוצרות את השירים היפים שלהן. השיחה איתו חושפת את נפלאות מודל המחקר של שירת הקנריות, ועד כמה המנגנונים המוחיים הקשורים לתנועה וללמידה הם מורכבים. כדי לפענח את המורכבות העצומה של פעילות המוח של הקנריות, נעזרים במעבדה שלו במגוון של כלי בינה מלאכותית. בריאיון הוא מסביר על מודל המחקר, ובאילו דרכים בינה מלאכותית יכולה לעזור.

דיוקן



ד"ר ירדן כהן

ד"ר ירדן כהן למד פיזיקה ומתמטיקה באוניברסיטה העברית במסגרת הצבא, ולאחר מכן שירת לא מעט שנים בצה"ל. לאחר שחרורו המשיך את לימודיו לתואר שני בפיזיקה במכון ויצמן, ואז החלה התעניינותו בחקר המוח. במסגרת לימודיו לתואר שלישי במחלקה לחקר המוח במכון ויצמן, ביצע מחקר שעסק בלמידת חוקים אצל קופים ואנשים. הפגישה עם המורכבות העצומה של הקורטקס הובילה אותו ללימודי בתר-דוקטורט בבוסטון שבארצות הברית, ולהתמחות במחקר של מערכת מורכבת מבחינת ההתנהגות ומבחינת פעילות המוח – שירת הקנריות. כשחזר לארץ לפני שלוש שנים וחצי, התקבל למשרת חוקר במחלקה לחקר המוח במכון ויצמן.

מראיינת: גילת בריל

אבל אצל קנריות אלה לרוב הזכרים ששרים. יש רכיבים בשירים שייחודיים לכל זכר, ויש רכיבים שמשותפים וחוזרים אצל זכרים רבים. הם בדרך כלל עושים מין תחרויות שירה, מעין כוכב נולד, הם מנסים להביס זה את זה בשירה.

מה למעשה מעניין אתכם לחקור? על אילו שאלות אתם מנסים לענות?

אנחנו מנסים לבדוק איך מוח הקנריות מלחין את השירים שלהן: אם בשירת הקנריות יש חוקי תחביר, חוקי סידור של ההברות, והם מורכבים והיררכיים, זה אומר שכשציפור צריכה לבחור את ההברה הבאה בשיר שלה, יהיה קשר למה שהיא שרה קודם לכן, לכמה עשרות הברות קודמות. למרות שאנחנו כמובן לא יכולים להגיד שלקנריות יש שפה כמו שפה אנושית, זה דומה לשפה שלנו, כשהתחביר במשפט הבא שנבחר להגיד משפיע על סדר המילים ותצורתן. לדוגמה, בעברית אנחנו יוצרים קשר בין הצורה של הפועל במשפט לבין המין והמספר של הנושא במשפט, ואפילו במשפט הבא. זה מצריך מאיתנו לזכור מה נאמר לפני כן. גם הציפור צריכה לזכור מה קרה קודם בתוך השיר של עצמה כשהיא בוחרת את ההברה הבאה. אנחנו שואלים מהו המנגנון העצבי במוח שמאפשר לה לזכור מה היא שרה קודם.

נתחיל דווקא במערכת הביולוגית שאתם חוקרים במעבדה, וממנה נעבור לבינה מלאכותית. מודל המחקר שלכם מאוד ייחודי, אתה יכול לספר עליו?

המעבדה שלנו משתמשת בציפורי שיר שנקראות קנריות כמודל כדי להבין איך המוח פועל, במקרה שלנו – איך המוח מלחין את השירים שהן שרות. הציפורים האלה אינן מפיקות סדרה אחת של צלילים, מה שאנחנו מכנים הברות, אלא מרכיבות כל שיר מצירופים שונים של הברות. כדי להפיק שיר הן למעשה מחילות כללי תחביר על ההברות שהן יודעות. הכוונה היא לכללים של סידור ההברות שלהן, שקצת מזכירים מה שקורה בשפה האנושית, ומאפשרים להן להפיק מגוון גדול ועשיר של שירים. מגוון השירים שהן מפיקות הוא למעשה החלון שדרכו אנחנו מנסים להבין את המנגנונים העצביים שבהם המוח של הקנרית מצרף את ההברות הללו ומיישם את כללי התחביר.

האם יש משמעות לתחביר של שירת הקנריות?

בטוח שלציפורים יש איזושהי משמעות, אבל אנחנו לא יודעים מהי בדיוק. אנחנו יודעים שהשיר נועד לתקשורת. הנקבות מקשיבות, הן כמעט לא שרות. אמנם באזור קו המשווה יש מינים של ציפורי שיר שאצלם הזכר והנקבה שרים גם דואטים,

איך אתם מנסים לענות על השאלה המורכבת הזאת?

מתבצעת בשכבות: כל שכבה מבצעת איזושהי פעולה מתמטית על התוצאה של השכבה הקודמת. סדרת הפעולות הללו נקראת רשת ניוונים מלאכותית. אבל בעצם זה רק שם. אלה לא ניוונים, והם לא דומים בשום צורה לניוונים ביולוגיים. זאת פונקציה מתמטית שהמקור הראשוני שלה אמנם שואב השראה ממחקר של תאי עצב ביולוגיים, אבל בכלל לא מדובר בניוונים כאלה.

איך האלגוריתמים האלה עוזרים למחקר על הקנריות?

כדי לענות על שאלת המחקר שלנו איך מוח הקנרית מלחין, גם אנחנו מפתחים כאלה אלגוריתמים, לא כל כך מתוחכמים כמו מודלי השפה שקיימים היום, את זה אנחנו לא צריכים, אלא כאלה שנועדו כמוהם לפתור פונקציות קלט ופלט. במקרה שלנו הקלט הוא עשרות אלפים רבים של שירי קנריות מוקלטים, בנוסף לפעילות של תאי העצב במוח בזמן שהן שרות.

הפלט שאנחנו מחפשים הוא התיוג של ההברות שמרכיבות את השירים של קנרית בודדת. כל הברה יכולה להיות אחת מתוך רפרטואר של אפילו חמישים סוגים של צלילים שונים שהציפור יודעת להפיק, והיא מפיקה שירים שיש בהם מאות הברות כאלה. מציאת התזמון של כל אחת מהן בשיר נחוצה לנו בשביל לחקור את פעילות המוח שתיעדנו באותו זמן.

פעולת התיוג מתבצעת על קובץ קול של הקלטת שיר של קנרית, ובסיומה נקבל סדרה של ההברות בקובץ, ובעבור כל אחת מהן נדע מאיזה סוג היא, מתי התחילה ומתי הסתיימה. זאת משימה מאוד קשה עד בלתי אפשרית לביצוע ידני: תיוג ידני של שיר נמשך בין חצי שעה לשעה. אם נכפיל בעשרות אלפים של שירים – גם גודל של מדענים לא יעזור. כדי לפתור את הבעיה אנחנו מפתחים מודלים, מאמנים אותם כמו שמאמנים כל מודל של למידת מכונה, ומשתמשים בהם אחר כך בשביל לתייג אוטומטית שירים של קנריות שעוד לא תייגנו. אנחנו עוברים עליהם לראות שהכול בסדר, אבל היתרון הוא שאין צורך להשקיע בתיוג כל כך הרבה זמן.

היבט אחר שבו אנחנו נעזרים בבינה מלאכותית במעבדה קשור

אחת הדרכים להבין מנגנון היא לבצע אנליזה שלו ברמות תיאור שונות, גישה שמשייכת לחוקר המוח [דייוויד מאר](#) מהמאה הקודמת. מכיוון שצירוף ההברות נועד לתקשורת – אנחנו מנסים להבין איזה מסר הצירוף של ההברות בתוך השיר מעביר לנקבות שמקשיבות לו וגם לזכרים אחרים. זאת אנליזה ברמת ההתנהגות עצמה.

רמה אחרת של אנליזה היא להבין את אופן פעולת הרשת העצבית: בתוך השיר עצמו, כשהציפור מרכיבה את המשפט שהיא שרה, היא לא שרה את ההברות באופן אקראי, אלא מחילה עליהן כללי תחביר. כדי להחיל את הכללים האלה צריך להפעיל איזושהו אלגוריתם, שאחד הרכיבים שלו, למשל, הוא הזיכרון, שכבר ציינתי קודם: הציפור צריכה לזכור מה שהיא שרה מוקדם יותר באותו שיר, כדי שההברה הבאה שהיא תבחר תתאים, שלא יהיה ג'יבריש.

רמה נוספת היא החומרה הביולוגית שמממשת אלגוריתם כזה. קיים מנגנון ביולוגי ברמת תאי העצב ואופן פעולתם, שמייצר את האלגוריתם שבסופו של דבר אחראי לתפקוד של הלחנת השיר ולהתנהגות. הרעיון הוא שאם נעבור את כל שלוש הרמות האלה, נוכל להבין היטב את המערכת.

איך בינה מלאכותית עוזרת לכם לבצע אנליזה של מנגנון ההלחנה בכל הרמות האלה?

אנחנו משתמשים במודלים או סימולציות של רשתות עצבים, כלומר, ברשתות ניוונים מלאכותיות.

חשוב לי להדגיש שהמילה ניוונים, ששגורה בתחום של הבינה המלאכותית, מטעה, כי כל אחד חושב על משהו אחר בהקשר של המילה ניוון. אני אסביר במפורט למה אני מתכוון:

נתחיל מאלגוריתמים ממוחשבים, או כלים שנקראים בינה מלאכותית, שהשימוש בהם נפוץ יותר. אלגוריתמים של רשתות ניוונים מלאכותיות נועדו לבצע חישוב על נתונים מספריים כלשהם, כדי לקבל איזושהו פלט. פעולת החישוב מקלט לפלט

מה ידוע על השלבים הראשונים של הלמידה, כשהגוזלים רק מתחילים ללמוד לשיר?

התנוונות. ככל הנראה ניוונים מתים בקיץ, וכשמגיע שוב סתיו ואחריו חורף נוצרים ניוונים חדשים, והמעגלים העצביים האלה נבנים מחדש. כלומר יש להם מערכת שכל שנה עוברת תהליך של הרס ובנייה, והם צריכים אחר כך להתאמן שוב בשירה, אבל הם זוכרים את רוב ההברות שהם ידעו לשיר בעונה הקודמת. אנחנו לא יודעים איך. אנחנו גם לא יודעים מה קורה לכללי התחביר שלהם. אחרי שפיתחנו את היכולת לתייג עשרות אלפי שירים נוכל לעקוב אחרי תהליכים כאלה. נוסף על כך נוכל לעקוב אחרי השירים עצמם, הלא מלאכותית, ואיך היא נהרסת ונבנית, ובמקביל אליה גם איך השיר נהרס ונבנה. הרעיון הוא לבצע אנליזה מרמת האנטומיה דרך רמת הפיזיולוגיה והפעילות של המוח, עד רמת ההתנהגות. יש לנו הרבה עבודה.

[במחקרים](#) משנות התשעים של המאה הקודמת, שתי חוקרות, קוהל ודופ, עקבו אחרי גוזלים של ציפורי שיר ומצאו שהם מקשיבים להורה שלהם, בדרך כלל לזכר, ואז כמו אצל תינוקות, נכנסים לשלב שמכונה קשקוש (babbling). בשלב הבא הם מתאמנים עד שהם מגיעים לרמת הביצועים של הבוגר. במעבדה אנחנו עוסקים כרגע בעיקר בצורת ההפקה של שיר בבוגרים, אבל כמובן שמעניין אותנו לחקור את תהליך הרכישה של המיומנות הזאת. אמנם זה יהיה עוד יותר מורכב, אבל אנחנו אוהבים מורכבות. עוד יתרון גדול שיש לנו בעבודה עם קנריות הוא שיש להן ולציפורי שיר אחרות עונת חזרו. השירים שלהן נועדו לחיזור, וגם לתחרות בין זכרים, באביב. כשתקופת האביב נגמרת ומגיע הקיץ, יש אזורים במוח שקשורים לשירה¹ שעוברים

1. חלק מהאזורים הפרה-מוטוריים.

מה זכור לך מהלימודים בתיכון?

למדתי כימיה ופיזיקה. בחרתי ללמוד בעיקר מתמטיקה, כי זה תחום שלא מבוסס על זיכרון. אפשר לפתח כל דבר ממשוואות ואתה לא צריך לשנן הרבה. במקצועות עיוניים, שבהם צריך לזכור הרבה, הייתי קצת פחות טוב. זכורים לי מורים מעוררי השראה. גם המורה לכימיה וגם המורה לפיזיקה הרשימו אותי ביכולת שלהם להמחיש מונחים ערטילאיים או קשים לתפיסה. לפעמים ההמחשה הייתה בדרך מאוד גבוהה מקצועית ולפעמים באמצעים פשוטים. אולי רק דוגמה אחת, בשיעור על פולימרים המורה לכימיה הביאה סיר פסטה שהיא בישלה. את זה אני זוכר היטב, ולא כי הפסטה הייתה טעימה יותר מדי. זה היה מקרוני ברוטב, ארוכים כאלה, בשביל להראות איך פולימרים יכולים להיראות. וזה היה מאוד משעשע. עובדה שאני זוכר.



לעזור מאוד במחקר, בכתיבה, בכתיבת קוד. אני מאוד ממליץ להיעזר בהם, אבל זה לא מדע מוח ביולוגי בסיסי.

האם לדעתך תעשיית הבינה המלאכותית עדיין יכולה לקבל השראה מהמדע?

אני חושב שכן. בעיבוד ראייה ותמונה התעשייה מזמן התרחקה מחקר המוח הבסיסי והתפתחה מאוד. אבל מקום שבו התעשייה הרבה מאחורי מה שאנחנו עושים, למשל, הוא בעיבוד סדרתי של רכיבים עם תחביר מעניין. אנחנו מגלים דברים על מוח של ציפורי שיר שאין להם מקבילה בתעשייה. בסופו של דבר אחת הבעיות הקשות בתעשייה של AI היא שכדי לאמן מודל גדול צריך הרבה מאוד כסף וכמות עצומה של אנרגיה (חשמל) למשך כמה חודשים, ממש בסדרי גודל של אנרגיה של מדינות שלמות. המערכת הביולוגית היא משהו הרבה יותר קטן, מוח של אורגניזם, שעושה ביצועים שחלקם הרבה יותר טובים מהמכונה, בשבר קטנטן של האנרגיה, של הזמן וכמובן של הכסף, ויש הרבה מה ללמוד ממנו. אנחנו מעבדה לחקר המוח ומעוניינים ללמוד איך הוא עובד. יש לי שיתוף פעולה עם חוקר בארצות הברית שמטרתו לפתח מודלים חדשים של AI קלאסי בשביל לייצר כלי מחקר טובים יותר, אבל זה חלק מהמחקר, כלי שמשרת אותו.

אתה יכול לספר קצת על התוצאות שלכם? מה גיליתם?

אחת התגליות שלנו קשורה לדרך שבה האזור במוח האחראי על השירה מפיק הוראה ליצור את ההברה הבאה בשיר. אזור השירה במוח של ציפורי שיר מקביל לקורטקס המוטורי אצל אצל יונקים (ראו איור 1), אותו חלק במוח ששולח אקסונים עד תאי העצב המוטוריים בחוט השדרה או בגזע המוח. בעופות נמצא איבר הקול ברום החזה, במקום שקנה הנשימה מתפצל לשני בرونכיים, ומעצבב אותו [העצב הגולגולתי ה-12](#), שנקרא תת-לשוני⁴. לאיבר הקול יש שרירים משני צידיו, והוא כמו כלי

לחקר המנגנון. מהו המנגנון הביולוגי שמממש את האלגוריתם של התחביר? לשם כך אנחנו מקליטים פעילות מוחית בציפורים שרות, בשיטות כמו [אופטוגנטיקה](#), שבה גורמים לתאי עצב להיות פלואורסצנטיים באמצעות הנדסה גנטית, ובעזרת מיקרוסקופים פלואורסצנטיים ממוזערים מתעדים שינויים בפלואורסצנציה שלהם; ובאמצעות [אלקטרופיזיולוגיה](#) - אלקטרודות דקיקות שמוודות שינויים בפעילות חשמלית של נוירונים. את הפעילות המוחית המוקלטת אנחנו מנסים לתפור יחד עם סימולציות של רשתות נוירונים. הפעם נוירונים קרובים לאמיתיים, כאלה שמבצעים ספייקים² חשמליים ויש להם קלט סינפטי. אנחנו מבצעים סימולציות כאלה כי אנחנו רוצים להבין איך רשת נוירונים כמה שיותר קרובה למציאות מסוגלת להפיק את פעילות המוח שאנחנו מקליטים כדי לייצר את השירה. אנחנו יוצרים סימולציה של רשת נוירונים שמסוגלת לייצר הברות של ציפורים ואת סוגי המעברים ביניהן, וכך לייצר את התחביר של הקנריות.

אז בעצם יש לכם גם מערכת בינה מלאכותית שעושה סימולציה של התחביר של השיר?

כן, וזה צד אחר של בינה מלאכותית, שפחות מעניין מהנדסים בגוגל. חשוב להגיד שיש איזו הפרדה בין העולם המחקרי לבין העולם ההנדסי. אם בעבר יכולנו לומר שהעולם ההנדסי-תעשייתי-מסחרי קיבל השראה מהעולם הביולוגי ומחקר המוח לפיתוחים שקראנו להם רשתות נוירונים - למשל אותו נוירון מלאכותי עם הרבה נתוני קלט ויצירת פלט יחיד; או צורות מסוימות, אותן שכבות נוירונים מלאכותיות שקיבלו השראה למשל מהקורטקס הראייתי³ - זה מזמן כבר לא שם. עכשיו נוצר מחדש נתק. התעשייה מתקדמת בצעדי ענק באמצעות כוח חישובי עצום והון עתק לשם אימון מודל שפה כדי לקבל מוצר נפלא. האם הוא דומה למוח? התשובה היא לא. האם נקבל ממנו השראה למוח? אנשים טוענים שכן, אני חושב שלא. אלה פרויקטים שלא יכולים להתקיים בתוך האקדמיה, אבל יכולים

2. דחף עצבי, פוטנציאל פעולה.

3. convolutional artificial networks: סוג של רשתות נוירונים, שבדומה לעיבוד הראייה אצל בני אדם, הופכות מוטיב חישובי החוזר במקומות שונים בתמונה (למשל גילוי קצוות, הבדלים בין חושך לאור, או קונטרסט) לאלמנט חישובי אחד, ומשתמשות בו על כל התמונה.

4. Hypoglossal cranial nerve

נשיפה שהמוח שלהם מנגן עליו באמצעות הוראות המגיעות מהקורטקס לגזע המוח ומשם דרך העצב התת-לשוני.

קצת היסטוריה וקצת מתמטיקה

מכונות המופעלות באמצעות אלגוריתמים לומדים הן תחום שקיים כבר מעל חמישים שנה. במכונה קיים רכיב שמקבל קלט, שגם הוא מספר, מפעיל עליהם חישוב ונותן תוצאה, פלט, שגם הוא מספר. הרכיב המקורי שבנה פרנק רוזנבלט בשנות החמישים נקרא **פרספטרון**. רוזנבלט חיווט פיזית חוטים של קלט לפלט, וניסה אחר כך לשחק עם המשקל היחסי של הקלטים כדי לקבל איזושהי פונקציה שתוביל לפלט רצוי כלשהו. במילים אחרות – ליצור מכונה שתקבל נתונים מספריים מסוימים ותלמד ליצור פלט המתאים להם. מכיוון שליחידה הזאת יש הרבה קלטים ופלט אחד היא מזכירה נירון, והרבה יחידות כאלה שמקושרות ביניהן נקראו רשת נייורונים.

בלי להיכנס יותר מדי למתמטיקה, גם אם מתחילים מנירון אחד – אז המשתנים בבעיה הם המשקלים: איזה משקל מתאים לכל אחד מנתוני הקלט כדי לקבל את הפלט הרצוי.

אלא שלא יודעים מראש איך לכוון את המשקלים. הראשוני שפיתחו נייורונים מלאכותיים, וביניהם רוזנבלט, פשוט סובבו חוגות, ובאמצעות ניסוי וטעייה חיפשו את הצירוף הנכון של משקולות לנתונים של הקלט. כמובן שמהר מאוד זה מסתבך, מכיוון שאם ליחידה אחת כזאת, נקרא לה נירון או פרספטרון, זה לא משנה, יש עשרה קלטים, עשר חוגות עם מספרים, קיים סיכוי קטן מאוד למצוא במרחב של עשרה ממדים כיוון מתאים לכל חוגה כדי לקבל את הפלטים שאנחנו מחפשים. וכשיש רשת של יחידות כאלה, יש מספר גדול מאוד של חוגות, וזה חסר סיכוי.

הפתרון לבעיה הזאת היה מתמטי. אני בטוח שהמוח לא עושה את זה. מדובר במה שמכונה הפצה לאחור, Back propagation, שהיא בעצם נגזרת של פונקציות מורכבות. כשהבינו שאפשר לבצע נגזרת, אפשר היה לאמן רשתות גדולות של יחידות כאלה, ששוב – הן אינן נייורונים. עם קפיצת היכולות הטכניות והמחשוב, יש לנו היום רשתות ענק, שככל שהן יותר גדולות ומורכבות אפשר לאמן אותן לבצע משימות יותר גדולות ומורכבות.

מצאנו שבאותו קורטקס מוטורי שמייצר את השירה בקנריות, יש יותר מצורת פעילות עצבית אחת בשביל לייצר את אותה הברה. כלומר, קיימים יותר מצבים נייורנליים מהברות. למה זה טוב? היתרון הזאת משמשת את הקנריות כאמצעי לזיכרון: אם השיר מגיע ליצירת ההברה הבאה עם היסטוריית הברות אחת – ההוראה ליצור את ההברה הבאה תועבר באמצעות נייורונים א-ב-ג; ואם השיר מגיע ליצירת אותה הברה עם היסטוריית הברות אחרת – ההוראה ליצור את אותה הברה תועבר עם נייורונים ח-ט-י. ואז, כשצריך לייצר מעבר חדש בשיר בהתאם למה שהיה קודם – הינה הזיכרון – פעילות מוח שמייצגת גם את ההברה המופקת וגם את ההיסטוריה של השיר. זה החלק האלגוריתמי, המגננוני, שמנסה להסביר איך המוח של הקנרית יכול לזכור איזה רצף הברות היה בשיר כדי להחליט מהי ההברה הבאה בשיר. זאת דרך אחת לפחות שבה הזיכרון של היסטוריית השיר יכול להישמר. הכוונה, שוב, היא לזיכרון שנחוץ ליצירת תחבי: צריך לזכור מה היה קודם באותו שיר, ולבחור את המעבר הבא בשיר. במערכת המוטורית, ראינו שזה מתרחש בעזרת יתירות במספר הדרכים לייצר כל הברה.


לאן התגלית הזאת מובילה אתכם בהמשך המחקר?

בימים אלה אנחנו משתמשים בתגלית הזאת בשביל לבדוק איך הדרכים ליצור את התחביר יכולות להתעדכן: האם הן מתעדכנות על ידי למידה או על ידי השפעות סביבתיות? אנחנו מתחילים עכשיו לערוך ניסויים שבהם ניצור הפרעות לשירה, וכך נגרום לקנריות לשיר רצפים קצת אחרים, כלומר נייצר שינויים במעברים שהן עושות בין הברות וכך בכללי התחביר. יש גם שינויים שקורים באופן טבעי, כתוצאה ממעבר של הזמן או השפעות סביבתיות. ולכן כשנינויים כאלה קורים, אנחנו מנסים לבדוק מה משתנה בפעילות המוחית. יש כמה היפותזות: אפשרות אחת היא שאלה שינויים עדינים בסיכוי לעבור מהברה להברה. יכול להיות שסיכויי המעבר מהברה אחת להברה אחרת מתוך כמה הברות שיכולות לבוא אחריה ישתנו אך ורק בגלל שהדרך, שבה ניתנת ההוראה לשיר את ההברה הנוכחית, משתנה קצת. זה יגרום גם למעבר הבא להשתנות. אבל באופן בלתי תלוי, יכולה להיות אפשרות אחרת, שמנגנון המעבר עצמו מהברה להברה משתנה. אנחנו מצליחים להראות שחייב לקרות גם שינוי במנגנון, כי אי אפשר להסביר את כל השינויים רק באמצעות שינוי בהברה הנוכחית.

המוח הקדמי
(המוח הגדול)

צרבלום
(המוח הקטן)


גזע המוח
(המוח האמצעי והמוח האחורי)



המוח הקדמי
(המוח הגדול)

צרבלום
(המוח הקטן)

גזע המוח
(המוח האמצעי והמוח האחורי)



איור 1: השוואה בין חלקי המוח של יונקים לבין חלקי המוח של עופות. האזורים המוטוריים (קורטקס מוטורי) הקשורים לתנועה נמצאים במוח הגדול ביונקים ובעופות.



אפשר לקשר את התוצאות האלה גם ללמידה בני אדם?

בדיוק. אנחנו רוצים לראות באיזה מנגנון מתרחשת הלמידה. בני אדם משנים כל הזמן את התחביר בשלל התנהגויות מוטוריות, כמו ריקוד, נגינה, כתיבה. כל אלה הם אותה משפחה של התנהגויות: אנחנו מייצרים סדרה של תנועות שמצייתת לחוקי תחביר. אלה סוגי הלמידה שמאוד מעניינים אותנו.

יש לנו אורגניזם, הקנרית, שלומדת לשיר באופן שמזכיר מאוד את הדרך שבה בני אדם לומדים לדבר. היא מפיקה רפרטואר עצום ועשיר של שירים שמצייתים לכללי תחביר מאוד מורכבים, היררכיים, גמישים, שמזכירים את מה שקורה בתרבות האנושית, ונוסף על כך יש לנו יכולת להקליט את הפעילות המוחית שלה בזמן שהיא שרה. היא גם משנה את המעגלים האלה משנה לשנה, ולומדת לאורך כל חייה. מכיוון שמדובר במערכת ביולוגית שמייצרת התנהגות מאוד מורכבת, גם מספר הדרכים שבהן למידה יכולה להתרחש הוא רב. אז זה מודל נהדר! אבל בגלל שהוא עשיר ומורכב אנחנו זקוקים למגוון כלים ממשפחת הבינה המלאכותית בשביל להשתלט על כל הנתונים ולנתח אותם.

האם אתם מוצאים קשר בין מנגנוני התחביר של שירת הקנריות למחלות נירודגנרטיביות? מומים? אוטיזם?

ברור שהיכולת להפיק או להבין כללי תחביר נפגעת בשלל מחלות ניווניות של המוח, כמו אלצהיימר, או פרקינסון, וגם באוטיזם זה מאוד בולט. יש איזו [משפחה באנגליה](#), שהתיעוד שלה הוא מלפני עשרות שנים, שיש להם איזו מוטציה שבגללה הם מתקשים ללמוד להפיק תחביר מורכב. האינטלקט לא נפגע, אבל השפה שהם מצליחים להרכיב היא מאוד בעייתית. המחקר בהיבטים הללו עדיין בחיתוליו, בעיקר משום שחסרים מודלים טובים בחיות מעבדה. אחת השיטות היא ליצור פגיעה מכוונת במוח, אבל בדרך כלל זה כלי מאוד גס. כמו כן ההיסטוריה של השיטה הזאת שנויה במחלוקת מבחינה אתית.

בציפורים היכולת להפיק שירה, בדומה ליכולת להפיק דיבור ביונקים, משויכת (בהפשטה מאוד גדולה) למסלולים מעגליים, מהקורטקס לתלמוס ובחזרה. אבל בניגוד ליונקים, קל יותר להפריד בין המסלולים בגלל שהקורטקס מסודר במקבצים של תאים שנקראים גרעינים. ככה זיהינו, למשל, שיש מעגל ספציפי, תלמוקורטיקלי כזה, שאם הוא נחתך, הציפור מפסיקה לשיר. זאת תוצאה פחות מעניינת באיזשהו מובן. אבל במקביל אליו קיים מעגל אחר, שגילינו שכאשר הוא נחתך, הציפור ממשיכה לשיר, ההברות מופקות באופן מדויק, אבל כללי התחביר שלה משתנים: סוגי המעברים משתנים, השונות משיר לשיר גדלה. זו רק תגלית ראשונית, ויכול להיות שיש פגיעות במוח שבאמת משנות את היכולת להפיק תחביר מסוים, ואולי תחבירים מסוימים.

יש הרבה חשש מבינה מלאכותית בקרב אנשים. איזה עתיד אתה צופה לה במחקר?

יש איזו בדיחה שאומרת שאנחנו רוצים לבנות מכונות שיעשו במקומנו כביסה וישטפו את הרצפה, ובמקום זה יצאו לנו מכונות שמחליפות אותנו בתור אומנים, בתור כותבים ובתור מדענים. בסוף המטרה שלנו היא להביא תועלת לאנשים. אם אנחנו יודעים להשתמש בכלי בינה מלאכותית בשביל לנתח נתונים

מהר יותר, או להעלות היפותזות, או לפתח אנליזות חדשות, כי הכלים האלה הופכים ליצירתיים, אז לדעתי זה מאפשר לשרת את האנושות טוב יותר, גם אם זה מייתר הרבה מהעבודה שלנו. בעיניי זה אפילו לא מייתר, כי זה מאפשר לעשות הרבה יותר ממנה. בעולם המתמטי, לדוגמה, כבר שנים מוכיחים משפטים מתמטיים בעזרת מודלים של בינה מלאכותית. צריך לזכור שכל מודלי השפה הגדולים הם בעצם חכמים כמו הנתונים שעליהם הם התאמנו, שהם כל מה שקיים ברשת. ככל שהם מייצרים עוד ועוד תוצאות, והתוצאות האלה מפורסמות ברשת, הם למעשה מתאמנים על התוצאות של עצמם. זה כבר פחות טוב, כי הם נהיים פחות מועילים ולא באמת יותר יצירתיים.

נוסף על כך, כמובן שכלי בינה מלאכותית לא אומנו להיות דוברי אמת, ולכן השימוש העתידי בהם בשביל שאלות מחקר, בשביל לפתח שיטות או אנליזות, צריך להיות מאוד זהיר. גם כשמבקשים מכלי לכתוב קוד. אם אתה לא יודע לכתוב קוד בעצמך ואתה לא יודע לבדוק את מה שהמכונה נתנה לך, אתה עלול לקבל דברים שיטעו אותך ויגרמו לך לפרסם שקרים. אבל אם אני יודע לכתוב קוד, אני יודע גם לבדוק אותו. כתיבת קוד תיקח לי שבוע. עם בינה מלאכותית זה ייקח עשר שניות וגם הבדיקה תיקח לי הרבה פחות זמן. לכן, במיוחד אם אני זקוק לקוד ככלי ואין לי עניין גדול בהישג של כתיבת הקוד, עדיף שזה יהיה מהר.

בעניין החששות הגדולים שהמכונות יהיו זדוניות, ישקרו באופן מגמת, ויקומו על יוצריהן – אני לא רואה לזה סימנים. נכון שאלגוריתמים שמתאמנים על כל דבר שיש ברשת יכולים די בקלות לבצע גניבה ספרותית, או לזייף. אבל אנשים עובדים לפתח מודלים שיהיו חסינים משקר, או יהיו בטוחים ולא יתנו תשובות זדוניות או מזיקות. זה עולם שלם וחשוב של אתיקת AI, ואין כאן הבדל בין עולם המדע לבין עולם החברה הכללית והשימושים הכלליים.

יש לך איזשהו מסר למורים לביולוגיה?

אחת העצות של הפסיכיאטר המפורסם ויקטור פרנקל (האדם מחפש משמעות) ביחס לשאלה איך ליצוק משמעות לחיים היא לא להפסיק להתפלא מהעולם. למורים יש את היכולת לעורר באנשים צעירים סקרנות גדולה, חשיבה ביקורתית, אהבה לעולם שסביבנו, פליאה ממנו; שימשיכו לפתוח עיניים, להיות סקרנים, לא לקבל את כל מה שהם רואים לפנייהם באופן פאסיבי. דבר גדול נוסף שאפשר לעשות זה לצקת בתלמידים ביטחון עצמי, את האמונה בעצמם, ביכולת שלהם להצליח. שני אלה, סקרנות ואמונה בעצמי, יכולים ללכת עם התלמידים לכל תחום בחיים: למעורבות החברתית שלנו, ולאמפתיה שלנו לאנשים אחרים ולצרכים שלהם.



השראה הדדית

תהליכי למידה במוח וברשתות עצביות מלאכותיות

מעובד על פי המאמרים¹:

Schmidgall, S. (2024): "Brain-inspired learning in artificial neural networks: A review". **APL Machine Learning** 2, 021501

doi: <https://10.1063/5.0186054>

Lillicrap, T.P., Santoro, A., Marris, L., Akerman, C.J. & Hinton, G. (2020): "Backpropagation and the brain". **Nature Reviews in Neuroscience**

21: pp. 335-346.


שלדג, אלא פותח בהשראת המבנה הביולוגי של מקור זה, כך שיפחית דחיסה של אוויר במנהרות שבהן הרכבת עוברת. לכן כאשר מוזכר המונח "רשתות עצביות מלאכותיות", אין הכוונה כי אלה רשתות של תאי עצב. למעשה, אלה מחשבים לכל דבר, המופעלים באמצעות אלגוריתמים. מבנה הרשתות הללו וחלק מהאלגוריתמים המפעילים אותן מנסים לחקות עקרונות של מבנה ושל למידה במערכות עצביות ביולוגיות, באמצעות מתמטיקה והנדסה. בהתאם לכך, גם אלגוריתמים ופונקציות מתמטיות שפותחו כדי ליצור רשתות עצביות מלאכותיות לומדות - יכולים לשמש השראה למודלים אפשריים שבהם המוח פועל (Lillicrap et al., 2020), ולהוביל לניסויים הבודקים אותם במערכות ביולוגיות.

גמישות סינפטית: השראה ביולוגית למכונות לומדות

הבסיס התאי לתהליכי למידה במוח הוא גמישות סינפטית⁴: שינויים בחוזק האותות המועברים בין תאי עצב דרך הסינפסה, ומפעילים או מעכבים פעילות של תאי עצב (Ho et al., 2011). בסינפסה, כידוע, אחד מקצוות האקסון של תא עצב פרה-סינפטי נמצא בסמיכות לאחת הבליטות על פני דנדריט של תא פוסט-סינפטי (איור 2). בעקבות גירוי כלשהו, עובר גל חשמלי בקרום התא הפרה-סינפטי. אם הגל החשמלי עובר סף מסוים⁵, הוא גורם לשלפוחיות בקצה האקסון לשחרר מוליך עצבי למרווח הסינפטי. במצב כזה נהוג לכוון את תא העצב הפרה-סינפטי "תא עצב יורה". קולטנים על פני קרום התא הפוסט-סינפטי קולטים את מולקולות המוליך שהשתחררו, ומפעילים שרשרת של תגובות בתוך התא. אלה יוצרות בתורן גל חשמלי העובר בקרום התא הפוסט-סינפטי, ואם הוא עובר סף מסוים, משתחררות שלפוחיות בקצה האקסון, ומופעל גל חשמלי בתאי עצב אחרים שיש לו איתם סינפסות, וכך הלאה.

העיקרון הרלבנטי לתהליכי למידה הוא שגירוי חוזר ונשנה מוביל לשינויים המחזקים את הסינפסה: לדוגמה, עלייה בכמות השלפוחיות ובגודלן בקצה האקסון של התא הפרה-סינפטי;

יצורים חיים מגיבים לגירויים מהסביבה באופן המאפשר להם ללמוד: להתנסות עם הסביבה, לקלוט גירויים ולהתנהג בהתאם. היכולת ללמוד משלבת מצד אחד זיהוי גירויים החוזרים על עצמם ואחסונם בזיכרון, ומצד שני שינוי של המידע כאשר הגירויים או ההקשרים שבהם הם מופיעים משתנים (איור 1; Statsenko et al., 2025). שינויים אלה קרויים בשם הכולל "גמישות מוחית": כל שינוי שחל ברמה התאית או ברמת רשתות של תאי עצב וקשרים בין אזורים שונים של המוח, שהוא תוצאה של התנסות או פעילות מסוימת של האורגניזם (Citri & Malenka, 2008).



איור 1: גמישות מוחית היא מכלול המנגנונים שבהם חלים במוח שינויים היוצרים למידה

גמישות מוחית היא מקור השראה לחיקוי תהליכי למידה ביולוגיים באמצעות מכונות, במה שמכונה כיום למידת מכונה ובינה מלאכותית. במידה רבה חל גם תהליך הפוך, שבו מחקרים על למידת מכונה מפרים את המחקר על המוח ומציעים מנגנונים אפשריים לתהליכים שבהם חלה למידה בתאי עצב (Zador et al., 2023). היסטורית, שני התחומים, הביולוגיה והמלאכותי, התפתחו יחד, ואף משתמשים פעמים רבות במונחים דומים (Shao & Shen, 2023).

במאמר זה נכיר שני מנגנונים המובילים ללמידה: האחד ביולוגי, שהיה מקור השראה ליצירת רשתות עצביות מלאכותיות², והאחר אלגוריתם מתמטי, המשמש השראה למחקר על אופן הלמידה במוח. לפני כן חשוב להבין שהקשר בין תהליכים ביולוגיים במוח לבין התנהלות הבינה המלאכותית הוא קשר ביומימטי³: תרגום של תהליך ביולוגי או של מבנה ביולוגי לצורכי פיתוח הנדסי או מתמטי. במילים אחרות, מדובר באנלוגיה, בדיוק כשם שמבנה הקטר ברכבת המהירה שפותח בִּפְנֵי אינו מקור של

1 הגרסה המובאת כאן היא סקירה של תוכני המאמרים המקוריים, ונועדה להנגיש את המידע לציבור המורים לביולוגיה. העיבוד כלל הוספת הסברים ואיורים לתכנים מורכבים, סינון מידע שאינו נקשר לרעיון המרכזי של הגרסה המעובדת, הגדרת מונחים מקצועיים, ובמידת האפשר קישור הדברים לתהליכי למידה והוראה. המעוניינים לקרוא את המאמרים המקוריים מוזמנים לפנות למקור לפי הפרטים המופיעים בתחילת הגרסה המעובדת.

Artificial neural networks 2

ביומימטריקה, biomimicry 3

synaptic plasticity 4

פוטנציאל פעולה 5

סינפטי יש מאות דנדריטים, ועל פני כל אחד מהם קיימות אלפי בליטות, שכל אחת מהן יכולה ליצור קשר עם אקסון של תא עצב אחר (Kasai et al., 2003).


פועל יוצא של מורכבות כזאת הוא הקושי לחזות כיצד הפעלה של תא עצב יחיד תוביל לשינויים בחוזקן של סינפסות אחרות באותו תא או בתאים אחרים, וכיצד שינויים אלה יתרמו לתהליכי למידה. אם נדרש סף מסוים של אותות העוברים מקצה אקסון אחד לבליטה אחת בדנדריט כדי להפעיל תא עצב פוסט-סינפטי, מהו השקלול של כלל האותות שתא פוסט-סינפטי מקבל מתאים המעצבים אותו? וכיצד השקלול הזה משתנה עם התקדמות הלמידה?

רשתות עצביות מלאכותיות תורמות תרומה מעניינת לניסיון לענות על שאלות דומות בתהליכי בינה מלאכותית.

מבנה רשתות עצביות מלאכותיות


אף על פי שרשתות עצביות מלאכותיות הן אלגוריתמים המפעילים מכונות, האופן שבו הן בנויות ומתוארות מזכיר מאוד רשתות של תאי עצב חיים.

לשם הפשטות, נכיר את יחידת המבנה של רשתות עצביות מלאכותיות: תא עצב מלאכותי (איור 3; Sadegh-Zadeh et al., 2024). כל תא עצב מלאכותי מקבל מידע ממספר תאי עצב מלאכותיים. מידע זה מגיע כקבוצה של נתונים מספריים $(x_1, x_2, \dots)$, המכונים "קלט". תא העצב עצמו יכולה לבצע הפונקציה מתמטית f , המתורגמת לאלגוריתם שמכונה יכולה לבצע. הפונקציה f מקבלת את הנתונים השונים של x , ובין השאר מחשבת את משקלם באמצעות ערכים מספריים המכונים "משקולות". לדוגמה, לנתון x_1 תהיה פונקציה משקולת w_1 , ל- x_2 תהיה משקולת w_2 וכולי. המשקולות הללו נקבעות מראש, והן יכולות להגדיל או להקטין את הערך המספרי של הנתון. הערך המספרי שהפונקציה מחשבת (y) הוא בעצמו נתון מספרי המכונה "פלט", העובר הלאה, לתא עצב מלאכותי אחר.



איור 3: מבנה בסיסי של תא עצב מלאכותי

עלייה בכמות הקולטנים למוליך העצבי בתא הפוסט-סינפטי (Beique et al., 2006); יצירת סיבי אקסון המייצבים את הבליטה בדנדריט של התא הפוסט-סינפטי (Kim et al., 2015); ואף עלייה בכמות הבליטות בדנדריטים ובהסתעפויות נוספות של האקסון, המאפשרות בנייה של סינפסות נוספות (Baily et al., 2015). חיזוק הסינפסות גורם לכך שהגל החשמלי אשר נוצר בתא הפוסט-סינפטי בעקבות האותות מהתא הפרה-סינפטי עובר את הסף הנחוץ להפעלת תא העצב הפוסט-סינפטי, וכתוצאה מכך הוא יורה בתדירות גבוהה יותר. שינויים אלה יוצרים זיכרון ולמידה, והם מכונים "למידת קב", על שם החוקר דונלד הב' שהציע את המנגנון. ההפך קורה כתוצאה משחרור מוליכים עצביים המעכבים את פעילות הסינפסה: חוזקה של הסינפסה נחלש כתוצאה מצמצום מבנים סינפטיים ואף התפרקותם, והתא יורה בתדירות נמוכה יותר.



איור 2: תהליכים המתרחשים בסינפסה גמישות סינפטית התורמת ללמידה תלוייה בחיזוק התהליכים המתרחשים בסינפסה והגברתם

ללמידת הב כמה מאפיינים מרכזיים: (1) כפי שנאמר לעיל, הזיכרון נוצר על ידי גירוי חוזר ונשנה המחזק או מחליש את הסינפסה; (2) כיוון הגירוי וההפעלה הוא תמיד בהפצה קדימה⁷, מהתאים שבאיברי החישה, דרך תחנות של עיבוד המידע במוח ועד לקורטקס.

עקרונות אלה של גמישות סינפטית מאפיינים את רמת הסינפסה היחידה. אולם תאי עצב במוח יוצרים רשתות, קבוצות של תאי עצב המקושרים ביניהם, שלרוב מופעלות (או מעוכבות) יחד. מבנה כזה יוצר מורכבות רבה: גופי התאים של תאי העצב ברשת עצבים מסוימת לא בהכרח נמצאים באותו אזור במוח. נוסף על כך, כל תא עצב ברשת כזאת יוצר סינפסות עם אלפי תאי עצב אחרים: קצה האקסון של תא עצב פרה-סינפטי מתפצל, וכל פיצול יוצר סינפסה עם תא עצב אחר. כמו כן, לתא פוסט-

Donald Hebb 6

forward propagation 7

לשם הפשטות, אנחנו מציגים רק חלק מהמאפיינים של הפונקציות המתמטיות המניעות את פעולתן של רשתות נוירונים מלאכותיות. בפועל, הפונקציות מורכבות, ויש בהן רכיבים נוספים מלבד נתונים ומשקלים

בינה מלאכותית רבים נבנות עם שכבות עומק רבות במיוחד, כדי לאפשר להן ללמוד ולבצע פעולות מורכבות מאוד, ומסיבה זאת קשה לדעת בדיוק אילו תהליכים חישוביים התרחשו והובילו לפלט מסוים שהתקבל בקצה הרשת.

כיצד מתרחשת למידה מורכבת ברמת רשתות עצביות מלאכותיות?

שינויים בחוזק הסינפסה וקביעת משקולות שונה לכל קשר בין תאי עצב מלאכותיים מתקשרים למנגנון שבו גירוי החוזר על עצמו מקבל ערך גבוה יותר ותורם להתחזקות הזיכרון. לדוגמה, תינוק לומד לזהות תפוח ירוק בכל פעם שמציגים לו תפוח כזה, ורשת עצבית מלאכותית תזהה תצלום של תפוח ירוק בכל פעם שתבצע ניתוח נתונים בתצלום של תפוח ירוק. אולם המציאות מורכבת הרבה יותר, והגירויים המתקבלים מהסביבה אינם חוזרים על עצמם תמיד, או שהם משתנים במעט. כיצד, אם כך, לומדת המערכת לזהות הבדלים, או במקרה שהיא טועה – לזהות את הטעות ולתקן אותה? ובדוגמת התפוח הירוק, מה יקרה למערכת כאשר יוצג לה תפוח אדום?


נתאר מקרה של מכונה שלמדה לזהות תפוח ירוק במגוון רב של תצלומים. בתצלומים אלה היא יצרה פלטים שהם מגוון של ערכים מספריים המזוהים על ידי כתפוח. כאשר מציגים למכונה תצלום של תפוח אדום, ייתכן שהיא לא תזהה אותו כתפוח ויתקבל פלט שגוי: לא תפוח. מכיוון שהסיבה היא שצבע התפוח מטעה את המכונה, יש לתת משקל נמוך יותר לכל החישובים והנתונים בשכבות המערכת השונות שנתנו משקל גבוה לצבע הירוק. אפשרות אחת היא לשנות את המשקולות של הקלט, כך שתאי העצב המלאכותיים המקבלים את נתוני הצבע הירוק יקבלו משקולות נמוכות יותר. אולם כאמור, בשל מורכבות

בפעולת תא העצב המלאכותי אפשר למצוא אנלוגיות לגמישות סינפטית⁹: בדומה לזרימת הגל החשמלי מהגירוי בלמידת הב, המידע זורם אל הנירונ המלאכותי וממנו והלאה; כמו כן, בדומה לסף עוצמת הגל החשמלי הנחוץ להפעלת תא העצב, למשקל של נתוני הקלט יש משמעות, כפי שקובעים ערכי x השונים והמשקולות השונות¹⁰. לדוגמה, אם משקולת w_1 גבוהה מ- w_2 , הרי ש- x_1 יתרום יותר לערך של y ; ובדומה לכך, ככל שהסינפסה בתא עצב חי חזקה יותר, כך היא תורמת תרומה גדולה יותר ללמידה בהקשר של הגירוי.

רשתות עצביות מלאכותיות מורכבות משכבות רבות של תאי עצב מלאכותיים המקושרים ביניהם, כך שפלט של תא עצב מלאכותי אחד הוא קלט של תא עצב מלאכותי אחר (איור 4; Sadegh-Zadeh et al., 2024).

המידע הנקלט ברשת עצבית מלאכותית מגיע מחיישן כלשהו (למשל, אמצעי אופטי כשמדובר בתמונה, אמצעי אקוסטי כשמדובר בקול), הממיר את המידע למספרים. המספרים הללו נקלטים בשכבת הקלט, ולאחר עיבוד באמצעות פונקציות ואלגוריתמים המידע עובר מהם הלאה, בכיוון שכבת הפלט, דרך שכבות עומק רבות. בכל אחת מהשכבות ברשת חל עיבוד של המידע באמצעות פונקציות רבות. הקשרים בין תאי העצב המלאכותיים נקראים סינפסות, ולכל קשר כזה יש כאמור גם משקולות.


באנלוגיה לרשתות עצבים במוח, גם ברשת מלאכותית קשה לחזות כיצד שינוי של משקולת באחד הקשרים של תאי עצב מלאכותיים בין השכבה הראשונה לבין השכבה השנייה ישפיע על הפלט שיתקבל מהמערכת כולה. רשתות מלאכותיות של כלי



איור 4: רשת עצביות מלאכותית. משמאל, שכבת הקלט (בכתום). שכבה זאת מקבלת את הנתונים מהחיישן הדיגיטלי. מימין, שכבת הפלט (בכחול). שכבה זאת מוציאה את הערך הסופי של הנתונים לאחר שעובדו ברשת. ביניהן נמצאות שכבות העומק (באדום), המבצעות עיבודים רבים לכל הנתונים שהתקבלו משכבת הקלט. באיור מתוארות ארבע שכבות עומק, אבל בפועל יש לרשתות עצביות מלאכותיות שכבות עומק רבות מאוד.

9 למידת הב אינה מקובלת במודלים המוכרים לנו כמו GEMINI ו-CHATGPT. אומנם קיימות גישות מחקריות שמנסות לקדם פתרונות המסתמכים על למידת הב, אך אלה לא התכנסו לשימוש יעיל בפתרונות המונגשים לציבור הרחב.

10 בהתאם לפונקציה הספציפית המחשבת את y .



איור 5: הפצה אחורה היא תהליך חישובי המשווה את הפלט הרצוי לפלט המצוי ומשנה את השקלול כך שהסיכוי לטעות יהיה נמוך יותר. בתהליך כזה מחשבים בכל פעם את הסטייה בין הערכים שהתקבלו בשכבת ניוונים מסוימת (לדוגמה בשכבה הכחולה) לבין הערכים שהיה רצוי לקבל ממנה. השוואה כזאת מאפשרת לשנות את המשקולות בין השכבות (לדוגמה בין השכבה הכחולה לשכבה האדומה שלפניה) כך שיתקבל הפלט הרצוי. חוזרים על התהליך בכל פעם מול שכבה פנימית יותר, עד למשקולות שבין שכבת הקלט (שכבה כתומה) לשכבה הפנימית הצמודה לה (שכבה אדומה שמאלית).

הערכים הרצויים מהשכבה הפנימית יותר ולהשוות בינם לבין הערכים שהתקבלו ממנה בפועל, ושוב לשנות את המשקולות בהתאם בשכבה שלפניה, וכך הלאה. לבסוף, יחושב השינוי של המשקולות המתאימות בין שכבת העומק הראשונה של הרשת לבין שכבת הקלט. תהליך כזה הופך את כיוון זרימת המידע, ונקרא "הפצה אחורה"¹¹ (Werbos, 1974; Rumelhart et al., 1986).

התוצאה של הפצה אחורה היא הקטנת הטעות שהתרחשה בשל צבע התפוח: קיימת סבירות גבוהה יותר שהמכונה תזהה תצלום של תפוח אדום כתפוח, כנראה משום שהמכונה תיתן משקל נמוך יותר לנתונים הקשורים לצבעים אדום וירוק, במונחים של למידה, המכונה למדה ליצור הכללה, כך שגם תפוח אדום וגם תפוח ירוק הם תפוחים.

לאור כל אלה, לתהליך הפצה אחורה יש מספר מאפיינים: (1) כיוון זרימת המידע מתחיל בהפצה קדימה, מהקלט לפלט, אך כולל גם הפצה אחורה, מהפלט לקלט; (2) תהליך הלמידה של הפצה אחורה יוצר משוב לפעולת המערכת, המתורגם לשינוי בחוזק הסינפסות; (3) אף שהשינויים מתרחשים רק בסינפסות מסוימות, הם מחושבים כך שפעילותה של כלל המערכת תשנה את הפלט¹².

האם גם המוח משווה?

אחת השאלות העולות בהקשר של הפצה לאחור היא, האם גם במוח מתרחשים תהליכים של השוואה בין המידע המתקבל מהמציאות באמצעות החושים לבין הזיכרון השמור במוח? ואם כן – מהם המנגנונים הביולוגיים המאפשרים למוח להעריך או

הרשת, קשה לדעת כיצד ישוקללו השינויים הללו בעומק הרשת המלאכותית. ייתכן שהשינויים שיעשו ייבלעו בתוך כלל השכבות ויעובדו כך שלא תהיה השפעה על הפלט. כיצד אפוא אפשר ללמד את המכונה שגם תפוח אדום הוא תפוח?

בתחום הבינה המלאכותית נמצא לבעיה מסוג זה פתרון מתמטי המבוסס על טווח הערכים של הפלט (איור 5): אפשר להשוות את טווח הערכים בשכבת הפלט שהמכונה מזהה כתפוח כשהתמונה היא תפוח ירוק, לטווח ערכי הפלט של המכונה כשהתמונה היא תפוח אדום, ולחשב מספרית את ההבדלים ביניהם. חישוב כזה מודד את הטעות, כלומר, את הסטייה מהערך הרצוי (Bishop, 1995).


בשלב הבא פונים לפלט של השכבה הקודמת, הפנימית יותר, ומחשבים איך לשנות את המשקולות בינה לבין שכבת הפלט הסופית כך שההפרש בין המספרים שיצרו טעות לבין המספרים הרצויים יהיה קטן יותר. על פי השינויים הללו אפשר לחשב את

המבנה של רשתות עצבים מלאכותיות וחלק מהאלגוריתמים המפעילים אותן מנסים לחקות עקרונות של מערכות עצביות ביולוגיות, באמצעות מתמטיקה והנדסה


11 Backpropagation. במנוחים מתמטיים מדובר בנגזרת של פונקציות מורכבות.

12 תהליך מעין זה מונחית "למידה מונחית" (Learning Supervised).

ב.



א.



איור 6: א. התפיסה הפשטנית של קשרים בין תאי עצב מניחה שהקלט והמשוב נקלטים על ידי תא העצב (חץ ירוק וחץ כתום) והפעלתו מעבירה מידע לאורך האקסון (חץ כחול) לתא העצב הבא. **ב.** תפיסה מורכבת של קשרים בין תאי עצב מניחה שבתאי עצב בקורטקס קיימים מדורים שונים שכל אחד מהם מקבל מידע מתאי עצב אחרים. כך למשל, בדנדריטים של תא העצב בקורטקס מתקבל קלט מתאי עצב אחרים (חץ ירוק). לעומת זאת, בהתפצלויות השונות של האקסון עשוי להתקבל משוב מתאי עצב אחרים (חיצים כתומים), כך שיתכן שמעבר המידע באקסון הוא דו-כיווני. כמו כן, תאי עצב נוספים יכולים לווסת מדורים שונים בתוך תא העצב (חיצים סגולים).

יצרו שדה רחב למחקר החותר לגלות מנגנון ביולוגי המאפשר למוח לאבחן את ההבדלים בין התפיסה בקורטקס¹⁴ לבין המציאות (Whittington & Bogacz, 2019).

מעבר לקלט ופלט חד-כיווניים

בלי להיכנס לפרטי המודלים המנסים להציע מנגנון לחישוב ההבדלים בין המידע הנקלט בחושים לבין המידע המאוחסן בקורטקס, חשוב לשים לב לכך שתאי עצב הם יחידת פעולה מורכבת. בעבר התפיסה הייתה שלכל תא עצב יש קלט מתא עצב אחר ופלט לתא העצב הבא, וגם המשוב מתקבל באופן דומה מתא עצב אחר (איור 6א). כיום, יותר ויותר עדויות מצביעות על כך שבתאי עצב קיימים אזורים קלט שונים (איור 6ב; Spruston, N., 2008). לדוגמה, ידוע שבתאי העצב בקורטקס יש הפרדה חשמלית בין האזור של פיצולי האקסון לבין גוף התא, שאף יכולה להתבטל בתנאים מסוימים (Larkum et al., 1999). עובדה זאת מעלה את השאלה אם באקסון עובר מידע באופן דו-כיווני, ואם כן – כיצד? מחקר על מעבר מידע בתוך תאי העצב עצמם עשוי להשליך אור על מנגנונים ביולוגיים לחישוב הבדלים במידע בין החושים לבין הקורטקס.

סיכום

מדעי המוח ולמידת מכונה הם שני תחומים שהתפתחו יחד, והובילו מצד אחד לניסיון ליצור מכונות הלומדות בהשראת תהליכי למידה במוח, ומצד שני לחפש מנגנונים המסבירים כיצד המוח לומד בהשראת הדרכים המתמטיות שבהן מכונות עושות זאת. הפצה לאחור וקידוד מנבא הם דוגמה אחת לכך, ויש כיום מחקרים ביומימטיים רבים המשלבים בין הבנת מנגנונים ביולוגיים לבין פיתוח פונקציות ואלגוריתמים לבינה מלאכותית (לדוגמה, Hiramoto & Cline, 2024). ההפרדה ההדדית הזאת ללא ספק עוד תמשיך להניב פירות בשני התחומים.


רשתות מלאכותיות של כלי בינה מלאכותית רבים נבנות עם שכבות עומק רבות במיוחד, ומסיבה זאת קשה לדעת בדיוק אילו תהליכים חישוביים הובילו לפלט מסוים מהרשת

לחשב את ההבדל בין המציאות לבין מה שכבר נלמד ולשנות או לשמר?

אין ספק שבתהליכי למידה מתרחשת כל העת השוואה בין ידע קודם לידע חדש. אולם עדיין לא ברור מהם המנגנונים המאפשרים למוח – לרשתות תאי עצב חיים – לבצע את ההשוואה הזאת ואת השינויים המתבקשים כתוצאה ממנה. מודלים למנגנונים כאלה הם השערות בלבד, ועדיין אין די עדויות לכך שהם אכן מתקיימים. אחד המודלים הללו מכונה "קידוד מנבא"¹³, ולפיו אזורים התמחות שונים במוח עוסקים בחיזוי הקלט הצפוי להגיע (Millidge et al., 2021). כלומר, ההשערה היא שהמוח עסוק כל העת בהשוואה בין מידע מהמציאות העובר במוח מלמטה למעלה, לבין מידע המאוחסן במוח, שמקורו בהתנסויות קודמות שהיו לנו באותו הקשר, ואשר עובר מלמעלה למטה.

האם בדומה ללמידת מכונה, המוח אכן מחשב את ההבדל בין המידע מהמציאות לבין מידע קודם המאוחסן ברמות גבוהות של המוח? ואם אכן המוח לומד באמצעות תהליך של קידוד מנבא, מהו המנגנון שבו הוא מבצע חישוב כזה? שאלות אלה

מנגנוני ויסות



איור 7: סינפסה משולשת של תא עصب פרה-סינפטי, תא עصب פוסט-סינפטי ואסטרואיט. נשאים למוליך העצבי (לדוגמה: גלומאט) מעבירים אותו מהמרווח הסינפטי לתוך האסטרואיט, וכך מווסתים את עוצמת האותות העוברים בסינפסה.

חלק חשוב של תהליך הלמידה במוח מתרחש באמצעות ויסות החוזק של סינפסות מסוימות. לאחרונה, הולכות ומצטברות עדויות רבות המעידות על ויסות של האותות הנוצרים באמצעות מוליכים עצביים בתהליכי זיכרון ולמידה.

לדוגמה, אסטרואיטים, סוג של תאי גליה, יוצרים שלוחות המשתתפות אף הן בסינפסה ליצירת סינפסה משולשת (איור 7). דרך קרום התא של השלוחות הללו נכנסות מולקולות של מוליכים עצביים ששוחררו מהתא הפרה-סינפטי למרווח בסינפסה, וכך חל ויסות של עוצמת האותות המתקבלים בתא הפוסט-סינפטי (Todd et al., 2006).

בתוך האסטרואיט המוליכים העצביים שנקלטו עוברים תהליכי פירוק. גם תאים מסוג מיקרוגליה יכולים לווסת כמויות של מוליכים עצביים, ואף לתקן רקמות פגועות כחלק מתהליכי למידה וזיכרון (Zhou et al., 2022).

קידוד מנבא ותעתועי ראייה

לעומת זאת, התמקדות במבנה דמוי פה בצד ימין של האיור מובילה את הקורטקס להשליך לתלמוס קידוד מנבא של ארנב ולהשוות את האיור אליו. בכל פעם, ההשוואה בין המידע מהמציאות מתבצעת עם קידוד מנבא שונה.

באותה דרך, הסולם והאדם שבתמונה, כל אחד בתורו גורם למוח שלנו להשוות את המידע מהתמונה להתנסות אחרת שלנו עם המציאות, כלומר לקידוד מנבא שונה בקורטקס. לכן, הפינה בין הקירות מפוענחת פעם כבולטת החוצה ופעם שקועה פנימה.

סוג מפורסם של תעתועי ראייה הוא אלה המציגים שתי אפשרויות לפענוח תמונה. לדוגמה, הארנב והברווז: רגע אחד אנחנו רואים ארנב, ורגע אחר – ברווז.

מודל של קידוד מנבא יכול להסביר במובן מסוים את התהליך המתרחש כשאנו צופים בתעתועי ראייה מסוג זה: מידע תחושתני ויזואלי מגיע למוח דרך העיניים, לתלמוס ומשם לקורטקס. התמקדות במבנה דמוי המקור הפתוח לצד שמאל של האיור מובילה את הקורטקס להשליך לתלמוס קידוד מנבא של ברווז ולהשוות את האיור אליו.



- Bailey, C. H., Kandel, E. R., & Harris, K. M. (2015): "Structural components of synaptic plasticity and memory consolidation". **Cold Spring Harbor perspectives in biology**, **7(7)**, a021758.
- Beique, J.C. et al. (2006): "Synapse-specific regulation of AMPA receptor function by PSD-95". **Proceedings National Academy of Science USA** **103**: pp. 19535–19540.
- Bishop, C.M. **Neural Networks for Pattern Recognition** (Oxford University Press, 1995).
- Citri, A. & Malenka R.C. (2008): "Synaptic Plasticity: Multiple Forms, Functions, and Mechanisms". **Neuropsychopharmacology Reviews** **33**: pp. 18–41.
- Hiramoto, M. & Cline, H.T. (2024): "Identification of movie encoding neurons enables movie recognition AI". **Proceedings of the National Academy of Sciences** **121(48)**: e2412260121.
- Ho, V.M., Lee J.-A. & Martin, K.C. (2011): "The cell biology of synaptic plasticity". **Science**, **334**: pp. 623–628.
- Kasai, H. et al. (2003): "Structure-stability-function relationships of dendritic spines". **Trends in Neuroscience** **26**: pp. 360–368.
- Kim, K. et al. (2015): "A temporary gating of actin remodeling during synaptic plasticity consists of the interplay between the kinase and structural functions of CaMKII". **Neuron** **87**: pp. 813–826.
- Larkum, M.E., Zhu, J.J. & Sakmann, B. (1999): "A new cellular mechanism for coupling inputs arriving at different cortical layers". **Nature** **398**: pp. 338–341.
- Lillicrap, T.P., Santoro, A., Marris L., Akerman, C.J. & Hinton, G. (2020): "Backpropagation and the brain". **Nature Reviews in Neuroscience** **21**: pp. 335–346.
- Millidge, B., Seth, A. & Buckley, C.L. (2021): "Predictive coding: a theoretical and experimental review". **arXiv preprint arXiv**: 2107.12979.
- Rumelhart, D., Hinton, G. & Williams, R. (1986): "Learning representations by back-propagating errors". **Nature** **323**: pp. 533–536. <https://doi.org/10.1038/323533a0>
- Sadegh-Zadeh, S.A., Bahrami, M., Soleimani, O., Ahmadi, S. (2024): "Neural reshaping: the plasticity of human brain and artificial intelligence in the learning process". **American Journal of Neurodegenerative Disease** **13(5)**: pp. 34–48. doi: 10.62347/NHKD7661. PMID: 39850545; PMCID: PMC11751442.
- Shao, F. & Shen, Z. (2023): "How can artificial neural networks approximate the brain?" **Frontiers in Psychology** **13**: 970214. doi: 10.3389/fpsyg.2022.970214
- Spruston, N. (2008): "Pyramidal neurons: dendritic structure and synaptic integration". **Nature Reviews Neuroscience** **9**: pp. 206–221.
- Statsenko, Y., Kuznetsov, N.V. & Ljubisaljevich, M. (2025): "Hallmarks of Brain Plasticity". **Biomedicines**, **13**: p. 460. <https://doi.org/10.3390/biomedicines13020460>
- Todd, K.J., Serrano, A., Lacaille, J.-C. & Robitaille, R. (2006): "Glial cells in synaptic Plasticity". **Journal of Physiology** **99**: pp. 75–83.
- Werbos, P. **Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences**. PhD Thesis, Harvard Univ. P. (1974).
- Whittington, J.C. & Bogacz, R. (2019): "Theories of error back-propagation in the brain". **Trends in Cognitive Science** **23**: pp. 235–250.
- Zador, A., Escola, S., Richards, B., et al. (2023): "Catalyzing next-generation artificial intelligence through NeuroAI". **Nature Communications** **14**: p. 1597.
- Zhou, M., Cornell, J., Salinas, S. & Huang, H.Y. (2022): "Microglia regulation of synaptic plasticity and learning and memory". **Neural Regeneration Research** **17**: p. 705.



מהפכת ה-AI בכיתת הביולוגיה:

כך שילבתי בינה מלאכותית בתהליך הביוחקר

קתי ביבי, רכזת ביולוגיה, אורט גרינברג קריית טבעון

תגובת מג"ק סקול לפרק מבוא שתלמידה כתבה בנושא "השפעת ריכוז מיצוי אננס על מידת פירוק הג'לטין":

נקודות חוזק

- "בחרת נושא מעניין ורלוונטי, והצלחת להסביר את חשיבותו בצורה משכנעת. במיוחד התרשמתי מהקישור שעשית לשוק העולמי של ג'לטין והצגת נתונים עדכניים."
- "הרקע המדעי שלך מקיף ומעמיק, במיוחד בהסבר על מבנה ותכונות הברומלין. השימוש במקורות אקדמיים מחזק את אמינות המידע."
- "הצגת בצורה ברורה את הקשר בין אננס וג'לטין, והסברת היטב את המנגנון הביוכימי של פעולת האנזים."

תחומים לשיפור

- "חסרה שאלת חקר והשערה מפורשות בסוף המבוא, כפי שנדרש בהנחיות. כדאי להוסיף אותן בפסקה נפרדת."
- "כדאי להוסיף תמונה או איור של התופעה הנחקרת, כפי שמצוין בהנחיות המקוריות."
- "המעבר בין הנושאים השונים יכול להיות חלק יותר - כדאי להוסיף משפטי קישור בין הפסקאות."

בעידן הדיגיטלי המתפתח במהירות, כלי בינה מלאכותית (AI) הפכו לחלק בלתי נפרד מחיינו. כמורה לביולוגיה, מצאתי את עצמי בצומת דרכים: לנסות למנוע שימוש של תלמידי בכלים אלה, או לאמץ גישה מעשית ולהפוך את הטכנולוגיה למנוף ללמידה משמעותית.

בחרתי באפשרות השנייה.

בשנים האחרונות זיהיתי אתגרים משמעותיים בתהליך כתיבת עבודת הביוחקר. תלמידים רבים מתקשים לכתוב עבודה מדעית על פי הנחיות מובנות ומפורשות; רוב המאמרים המדעיים האיכותיים כתובים באנגלית, שפה שהרמה בה בקרב חלק מהתלמידים אינה מספיקה להבנת טקסטים מדעיים מורכבים; ולבסוף, תלמידים נוטים להסתמך על מקורות מידע מצומצמים ולעיתים לא אקדמיים, בשפה העברית. במקום להתעלם מהמציאות שבה תלמידים ממילא משתמשים בכלי AI, אימצתי את הגישה שמציעה: "אם אי אפשר לנצח אותם - הצטרף אליהם". החלטתי להטמיע את השימוש בכלים אלה בצורה מושכלת, מבוקרת ומקדמת למידה.

במסגרת הניסוי, שילבתי בתהליך כתיבת עבודת הביוחקר שני כלים עיקריים. הראשון הוא כלי ייעודי שיצרתי בפלטפורמת מג"ק סקול (Magic School) שנועד להנחות תלמידים בכתיבת פרקי המבוא והדיון בעבודת הביוחקר. התהליך עובד בצורה פשוטה ויעילה: התלמידים כותבים טיוטה של המבוא או הדיון, מכניסים את הטקסט לתוך הכלי - ומקבלים משוב מפורט. בשונה מכלי AI רגילים, המשוב ממוקד בדיוק בדרישות של עבודת הביוחקר - מה חסר במבוא או בדיון לפי ההנחיות הרשמיות, וכיצד לשפר את הניסוח מבחינה מדעית. הכלי לא רק מצביע על הבעיות, אלא גם מציע הנחיות קונקרטיות לשיפור, תוך שמירה על הקול האותנטי של התלמיד.

הינה דוגמה להתכתבות של תלמידה עם הכלי שיצרתי במג"ק סקול, המדגימה את אופי המשוב:

במקום להתעלם מהמציאות שבה תלמידים ממילא משתמשים בכלי AI, החלטתי להטמיע את השימוש בכלים אלה בצורה מושכלת, מבוקרת ומקדמת למידה.



השילוב המכוון של כלי AI בתהליך כתיבת עבודת הביוחקר הוביל לכמה תוצאות חיוביות מפתיעות

התוצאות לא איחרו לבוא. השילוב המכוון של כלי AI בתהליך כתיבת עבודת הביוחקר הוביל לכמה תוצאות חיוביות מפתיעות: ניכר הבדל משמעותי באיכות העבודות של תלמידים שהשתמשו בכלים בצורה מושכלת; נצפתה רמת העמקה גבוהה יותר בפרקי המבוא והדיון; תלמידים החלו להסתמך על מאמרים מדעיים באנגלית; ואחרי ההפתעה הראשונית מהיתר להשתמש בכלי AI התלמידים דיווחו על חווית למידה משמעותית יותר. "ברור לי שתעשו את זה בכל מקרה", אמרתי להם, "אז אם כבר, אני רוצה שתעשו את זה בצורה מושכלת ונכונה."

התהליך לא היה נטול אתגרים, כמובן. נדרשתי להתמודד עם סוגיות שונות, למשל: כיצד לוודא שהתלמידים אכן מבינים את החומר ולא רק מסתמכים על הכלי; כיצד לוודא שהתלמידים מפעילים שיקול דעת ביחס למידע שהם מקבלים מהכלי; וכיצד להעריך עבודות בצורה הוגנת, כאשר חלק מהתלמידים משתמשים בכלים מתקדמים יותר מאחרים. אחד מהפתרונות שמצאתי היה מבחן בעל-פה על העבודה, שאפשר לי לבחון את רמת ההבנה האמיתית של התלמידים.

בהתבסס על הניסיון שלי, אני ממליצה למורי ביולוגיה לאמץ גישה מעשית – להכיר בכך שתלמידים משתמשים בכלי AI ולכוון אותם לשימוש נכון; לפתח כלים ייעודיים ולחבר פרומפטים ספציפיים לצורכי הביולוגיה ועבודת הביוחקר; להגדיר כללים ברורים ולקבוע גבולות לשימוש בכלים אלה, בהקפדה על שקיפות; לשלב מנגנוני אימות כמו מבחנים בעל-פה או הצגות בכיתה כדי לוודא הבנה אמיתית; ולהישאר מעודכנים בהתפתחויות בתחום ה-AI החינוכי.

שילוב כלי AI בהוראת הביולוגיה, ובפרט בתהליכי עבודת הביוחקר, הוא הזדמנות לשינוי משמעותי את הלמידה. במקום להימנע מהטכנולוגיה, אפשר לרתום אותה לטובת העמקת ההבנה, הנגשת ידע מדעי מתקדם, ופיתוח מיומנויות המאה ה-21. הניסיון שלי מראה כי כאשר התהליך מנוהל נכון, התוצאה היא תלמידים מעורבים יותר, עצמאיים יותר, ובעלי הבנה מעמיקה יותר של תוכני הביולוגיה. כמורים לביולוגיה, אנו נמצאים בעמדה ייחודית להוביל את השינוי הזה – לא כמתנגדים לטכנולוגיה, אלא כמנחים מיומנים המראים לתלמידים כיצד לנצל אותה באופן ביקורתי, יצירתי ואחראי.

הכלי אף מציע הצעות קונקרטיות להרחבת העבודה: "הנה הצעות ספציפיות להרחבת המבוא שלך ל-2-3 עמודים: הרחבת הרקע המדעי..." וכך הלאה, עם פירוט של נושאים ספציפיים שהתלמידים יכולים להרחיב.

מה שמעניין במיוחד הוא שהכלי גם שומר על יושרה אקדמית, כפי שניכר בדוגמה נוספת: כאשר תלמיד שאל "אתה יכול לעשות את זה?" (כלומר, לכתוב את העבודה עבורו), הכלי השיב: "סליחה, אבל אני לא יכול 'לעשות' או לכתוב מחדש את העבודה עבורך. זה יהיה צורה של רמאות אקדמית." במקום זאת, הכלי הציע דרכים לגיטימיות לעזור לתלמיד להתמודד עם האתגר.

הכלי השני היה שימוש בכלי AI כלליים¹ להנגשת מאמרים מדעיים. מכיוון שבחלק מכלי ה-AI קיימת הגבלת גיל, תלמידים בני פחות מ-18 שנים² השתמשו ב-ChatGPT, בעוד אלה שעברו את גיל 18 השתמשו ב-NotebookLM, שמתמחה בסיכום מאמרים בצורה יעילה יותר. הנחיתי את התלמידים להשתמש בכלים אלה בדרכים מגוונות, מעבר לתרגום פשוט: הם למדו לבקש, בעבור מושגים מורכבים, הסברים המותאמים לרמת הידע שלהם; לבקש סיכום ממוקד של ממצאים עיקריים של מחקרים; ואף לבקש השוואה בין מאמרים שונים כדי לזהות מגמות במחקר. דגש מיוחד הושם על כך שהתלמידים יבינו את המידע ולא רק יעתיקו אותו.

במקום לאסור את השימוש בכלים אלו העדפתי להגדיר כללי משחק ברורים: הדגשתי כי הכלים נועדו לעזור בהבנת מקורות מידע ולא להחליף אותם; עודדתי שימוש רב יותר במאמרים מדעיים באנגלית והוצאתי את התלמידים מאזור הנוחות של חיפוש בעברית בלבד; הנחיתי אותם לתכנן את מבנה העבודה ולחשוב על השאלות שלהם לפני השימוש בכלי AI; ובנוסף, עודדתי חשיבה מעמיקה והבנה באמצעות מבחן בעל-פה על תוכן העבודה.

1. הכוונה כאן היא לכלים מוכרים, כמו ChatGPT, שהשימוש בהם הוא לצרכים מגוונים. לעומתם Magic School, שהוא כלי ייעודי למערכת החינוך.

2. שימו לב: על פי הנחיות משרד החינוך, שימוש ב-ChatGPT מתחת לגיל 18 מצריך אישור הורים.



דוגמה לחלק מפרק מבוא שכתבו תלמידים בעזרת המג'יק סקול, ללא התערבות שלי כמורה:

מבוא

התפשטות עמידות חיידקים לאנטיביוטיקה מהווה איום מרכזי לבריאות הציבור ברחבי העולם. ארגון הבריאות העולמי (WHO) מזהיר כי עמידות אנטיביוטית עשויה להוביל למשבר גלובלי בתחלואה ובתמותה מזיהומים אשר בעבר היו ניתנים לטיפול פשוט. בין הגישות החדשניות המתפתחות להתמודדות עם הבעיה, עולה עניין רב בחומרים טבעיים כבעלי פוטנציאל אנטי-מיקרוביאלי (Kabrah et al., 2016).

אחד מהחומרים המבטיחים בתחום זה הוא הבצל (*Allium cepa*), ירק נפוץ המוכר בזכות סגולותיו הבריאותיות והשפעותיו הרפואיות. הבצל עשיר בתרכובות גופרית אורגניות ובפלבונואידים, אשר נמצאו במחקרים כיעילים בעיכוב פעילות חיידקית ואף בהרס מבני התא של חיידקים שונים. המאפיינים הללו מצביעים על פוטנציאל של הבצל לשמש חלופה טבעית וברת-קיימא לטיפולים אנטיביוטיים קונבנציונליים, במיוחד לאור עמידותם הגוברת של זני חיידקים פתוגניים לטיפולים קיימים (Healthline, 2023).

במחקר הנוכחי, נבדקה השפעת ריכוזי מיצוי הבצל על קצב גידול של חיידק *Escherichia coli* (*E. coli*). חיידק זה, המוכר כתושב רגיל במערכת העיכול האנושית, הוא גם אחד החיידקים המזיקים ביותר כשמדובר בזיהומים. מחקר זה נועד לתרום להבנת המנגנונים הפיזיולוגיים שבאמצעותם חומרים טבעיים, כמו הבצל, עשויים לעכב את גדילתם של חיידקים פתוגניים.

הבצל, המשתייך למשפחת השושניים (*Alliaceae*), נחשב לירק פונקציונלי בשל הרכבו הכימי הייחודי. הוא מכיל תרכובות גופרית אורגניות, כגון אליצין ותיוסולפינטיים, הידועות ביכולתן לפגוע במבני התא של חיידקים ולהפריע לפעילותם התקינה (Kabrah et al., 2016). מנגנון הפעולה העיקרי של תרכובות אלו כולל פירוק מבנה ממברנת התא ושיבוש פעולתם של אנזימים במעגל קרבס, החיוניים לייצור אנרגיה תאית (Medical News Today, 2023).

בנוסף, הבצל מכיל פלבנואידים כמו קוורצטין, הממלאים תפקיד מרכזי בנטרול רדיקלים חופשיים. השפעתם מגבירה עקה חמצונית בחיידקים, דבר המוביל לשיבוש תהליכים ביולוגיים קריטיים בתא. יחד, רכיבי הבצל מציגים מנגנונים רב-שכבתיים המיועדים למנוע גדילת חיידקים, ובכך מציעים גישה טבעית למניעת זיהומים (Healthline, 2023).

Escherichia coli, או בקיצור *E. coli*, הוא חיידק גרם-שלילי ממשפחת *Enterobacteriaceae*. הוא מאופיין בגמישותו וביכולתו לגדול בתנאים מגוונים, בטמפרטורה אופטימלית של 37°C וסביבת pH ניטרלית (6.5-7.5). בשל מהירות גידולו ותפקודו הפשוט יחסית, הוא משמש מודל מחקרי חשוב במעבדות (האוניברסיטה הפתוחה, 2023).

עם זאת, מבנה הממברנה החיצונית של *E. coli* מקנה לו עמידות מסוימת לחומרים אנטי-מיקרוביאליים, המעלה את הצורך בפיתוח גישות המשלבות רכיבים טבעיים פעילים המסוגלים לחדור מבנה זה ולפגוע במערכות התא.

הקשר בין ריכוזי מיצוי הבצל לבין קצב גידול חיידקי *Escherichia coli* מבוסס על פעילותן של תרכובות גופרית ופלבונואידים המצויות בבצל. תרכובות הגופרית, כמו אליצין ותיוסולפינטיים, פועלות להפרת שלמות ממברנת התא החיידקי. כתוצאה מכך, מתרחשת דליפה של יונים וחומרים חיוניים מהתא, דבר שפוגע ביכולת החיידק לשמור על סביבה פנימית תקינה, המהווה תנאי הכרחי להתרבות ולשרידות התא.



העלאת ריכוזי מיצוי הבצל עשויה להעצים את ההשפעה המעכבת, שכן ריכוז גבוה יותר של תרכובות פעילויות יגביר את עוצמת הפעולה הכימית על דופן התא ועל מנגנונים מטבוליים פנימיים. באופן זה, קיימת ציפייה שהיחס בין ריכוז המיצוי לקצב הגידול של החיידקים יהיה הפוך, כאשר ריכוזים גבוהים יותר של מיצוי יגרמו לעיכוב משמעותי יותר בקצב גידול *E. coli*.

בנוסף, חשוב לציין כי יעילות החומרים הפעילים תלויה גם בתנאי הסביבה, כמו טמפרטורה, pH, וזמינות חומרים מזינים במצע הגידול. שינויים בתנאים אלו עשויים להשפיע על מנגנון הפעולה של התרכובות ולשנות את עוצמת ההשפעה שלהן על קצב הגידול של החיידקים. הבנת הקשרים הללו עשויה לשפר את יכולתנו להשתמש במיצוי בצל באופן מבוקר ויעיל כנגד זני חיידקים פתוגניים.



אפשר לסמוך עליך?

גורמים המשפיעים על אמון בכלי בינה מלאכותית

מאמר מעובד על פי¹:

Zerilli, J., Bhatt, U. & Weller, A. (2022): "How transparency modulates trust in artificial intelligence". *Pattrens* 3(4). <https://doi.org/10.1016/j.patter.2022.100455>

התנהגויות של אמון במכונות

כל כלי בינה מלאכותית יכול לעורר מגוון התנהגויות של אנשים בהקשר של אמון במכונות, שאותן אפשר לתאר באמצעות רצף (איור 1): בקצהו האחד, אנשים המפגינים חוסר אמון. בצורה הקיצונית של התנהגות זו, המשמעות היא סירוב להשתמש בכלי או לקבל את תוצאותיו, כלומר התנגדות לכלי (Dietvorst et al., 2018). בקצהו השני של הרצף אנשים המפגינים אמון מוחלט בכלי, מפסיקים לבדוק את פעולתו, ומקבלים את המלצותיו ללא עוררין (Dzindolet et al., 2003). אנשים המתנהגים כך מפגינים ביטול עצמי.

בין התנהגויות אלה נמצאות על הרצף התנהגויות של אמון יתר, המתאפיינות באימוץ רוב ההמלצות של הכלי, או חוסר אמון רב, המתאפיינות בדחיית רוב ההמלצות של הכלי (Logg et al., 2019). במרכז הרצף אנשים המפגינים ערנות: נתינת אמון שקולה ומותאמת לביצועי הכלי ולחיסרונותיו, תוך ביקורת מותאמת על ההמלצות המתקבלות ממנו, ושאיפה למצות בצורה הטובה ביותר את השיתוף בין האדם למכונה.

באופן טבעי, כאשר הכלי בעל ביצועים מצוינים ואחוזי טעות קטנים יחסית, התנהגות של הערכה, שבה מקבלים את רוב המלצות הכלי, היא מאוד רצויה ומתאימה. בהתאם לכך, כאשר הכלי בעל אחוזי טעות גדולים יחסית, התנהגות של דחייה, שבה רוב המלצות הכלי נדחות, אף היא מאוד רצויה ומתאימה (Zerilli et al., 2019). עם זאת, כלי בינה מלאכותית רבים אינם כושלים עד כדי כך, אך גם אינם חפים מטעויות, ולכן אמון יתר או חשדנות יתר אינם מתאימים. בתנאים כאלה השאלה היא מה משפיע על דרגת האמון שאנשים נותנים בכלי ואיך אפשר לעודד ערנות.

השפעת טעות של הכלי על דרגת האמון

מחקרים רבים בנושא התנהגות של הערכה ודרגה גבוהה מאוד של אמון מצביעים על הקשר גינה לבין תפיסת יכולותיו של הכלי לטעות. אמון יתר מאפיין מצבים שבהם אנשים תופסים את יכולות המכונה כטובות הרבה יותר מאלו של עצמם, ואינם מחפשים עדויות תומכות נוספות להמלצה של הכלי או לפלט שהתקבל ממנו (Manzey et al., 2012). ביטוי קיצוני לכך מתרחש


האם אתם מוכנים שכלי AI ינהג במקומכם במכונית? שכלי AI יפענח תצלום נטען שעשיתם לכף הרגל? שיבדוק ויעריך תשובות שהתלמידים שלכם כתבו לשאלות פתוחות? או שישוחח איתכם במסגרת טיפול פסיכולוגי?

בהגדרתה, בינה מלאכותית (Artificial intelligence, AI) היא היכולת של מכונה לבצע משימות המצריכות אינטליגנציה אנושית. יש משימות שבהן יכולת הביצוע של המכונה עולה על יכולת הביצוע של האדם, בין השאר בשל העיסוק בחישובים מורכבים ובכמויות גדולות מאוד של נתונים. ואכן, כלי בינה מלאכותית רבים ומגוונים, כמו צ'אטבוטים, רובוטים ומכונות אוטומטיות, חודרים יותר ויותר לחיי היומיום שלנו, ובכל תחום אפשרי מחליפים חשיבה אנושית. יכולות הביצוע של הכלים הללו הולכות ומשתפרות עד כדי התייחסות אליהם כאל סוכנים עצמאיים, בעלי אמונות ומטרות משלהם (Castelfranchi, 1998). במידה רבה, הקבלה של כלים אלה בחיינו וההחלטה להסתמך עליהם תלויות באמון שיש לנו כלפיהם (Kelly et al., 2023). כלי בינה מלאכותית נתונים, אפוא, ליחסי צוות אדם-מכונה, ואנחנו יכולים לקבל אותם, להתעלם מהם ואף לחשוש בהם (Castelfranchi & Falcone, 2000). מאמר זה עוסק בדרכים שבהן תפיסות אנושיות שונות של טעויות שמבצעים כלי בינה מלאכותית² פוגעות באמון בהם, וכיצד אפשר לתקן אמון שנפגע. בסיומו, ננסה להבין כיצד אמון ביחס לכלי בינה מלאכותית יכול לסייע בפיתוח משימות לתלמידים בשדה ההוראה.

לפני שננסה להבין מה ידוע על אמון בין אנשים למכונות והפרתו, חשוב לשים לב להבדלים בין יחסי אמון בין אנשים לבין יחסי אמון בין אדם למכונה. בפסיכולוגיה ארגונית וחברתית נהוג להתייחס לשני רכיבים עיקריים המשפיעים על יצירת אמון בצוות: האחד הוא יכולתו של מושא האמון, האדם שבו נותנים את האמון, לבצע את המשימה. השני הוא המידה שבה מושא האמון מראה כוונות טובות, או בעיקר, היעדר כוונות שליליות מצידו (Thielmann & Hilbig, 2015). ביחסי אדם-מכונה, רכיב היכולת לבצע את המשימה קשור לדיוק שבו מבצעת אותה המכונה; ורכיב הכוונות קשור לשקיפות, כלומר ליכולתה של המכונה להסביר את אופן ביצוע המשימה וההחלטות שהתקבלו במהלך ביצועה³.

1. הגרסה המובאת כאן היא סקירה של תוכני המאמר המקורי, ונועדה להנגיש את המידע לציבור המורים לביולוגיה. העיבוד כלל הוספת הסברים ואיורים לתכנים מורכבים, סינון מידע שאינו נקשר לרעיון המרכזי של הגרסה המעובדת, הגדרת מונחים מקצועיים, ובמידת האפשר קישור הדברים לתהליכי למידה והוראה. המעוניינים לקרוא את המאמר המקורי מוזמנים לפנות למקור לפי הפרטים המופיעים בתחילת הגרסה המעובדת.

2. קיימים גם רכיבים נוספים המשפיעים על יחסי אמון. לדוגמה: מורכבות המשימה.



איור 1: רצף של התנהגויות אמון בכלי בינה מלאכותית

מחקרים מראים שבמצבים של חוסר ודאות אנשים בוחרים את דרך קבלת ההחלטות לא על פי אמינותה, אלא על פי תפיסתם ביחס לסיכוי שההחלטה תהיה מושלמת (Dietvorst & Bharti, 2020): כך למשל, במהלך נהיגה אנשים מעדיפים קבלת החלטות אנושית, הידועה בטעויות רבות, על פני נהיגה אוטומטית. זאת משום שאלגוריתמים לנהיגה אוטומטית נתפסים כפחות קרובים למציאות, אף על פי שהם אמינים מאוד. כלומר, במקרה של קבלת החלטות אנושית קיימת נטייה לסבילות לטעויות, בעוד שבקבלת החלטות באמצעות אלגוריתמים קיימת אי-סבילות לטעויות. אי-סבילות לטעויות יכולה להסביר מדוע כאשר האלגוריתם עושה טעות אחת בלבד הוא נענש בחומרה ונדחה כליל: תקוותיהם של המשתמשים בו להחלטה מושלמת מתנפצות, ודווקא הדרך רצופת הטעויות של קבלת החלטות אנושית נראית בעלת סיכוי רב יותר להתקרב לשלמות. כל אלה מדגישים את הממצאים שלטעויות יש השפעה משמעותית על אמון, אפילו יותר מאשר לפלט נכון של האלגוריתם (Manzey et al., 2012). לכן ריכוז תוצאות חיובי בסיום המשימה, המציין עד כמה הכלי הצליח בביצועה, לא בהכרח יעזור לשקם יחסי אמון שנפגעו כתוצאה מטעות (Dzindolet et al., 2003).

כיצד אפשר לבנות יחסי אמון מותאמים בין אדם למכונה?

כאשר גם הצלחות מוכחות ואחוזי טעות נמוכים אינם מספיקים לבניית אמון בכלי בינה מלאכותית, עולה השאלה: מה עשוי בכל זאת לסייע?

אחד הכיוונים העיקריים לבניית אמון, שמסייע גם ביחסי אנוש, הוא שקיפות: ההבנה שלנו, המשתמשים, מה גרם לטעות של כלי הבינה המלאכותית שבו השתמשנו.

דרך אחת לייצר שקיפות היא הסבר על האופן שבו האלגוריתם עובד, ומה המקור לטעויות שהוא מבצע (Lee & Moray, 1992). להסברים אכן נמצאה השפעה חיובית על אמון, אך הם עלולים גם להזיק במובנים מסוימים. כך למשל, כאשר הכלי מסביר למשתמשים המלצה לפני שהם מתבקשים להעריך אותה בעצמם, המשתמשים נוטים להשתמש בהמלצה, גם אם היא לא תמיד מתאימה להם או לא תמיד נכונה (Bansal et al., 2021). כלומר, שקיפות רבה מדי עלולה לגרום למשתמשים לקבל את

כאשר אנשים מעדיפים את המלצת הכלי אף על פי שקיימות עדויות הסותרות אותה (Pazouki et al., 2018). המעניין הוא שהתנהגויות אלה כמעט אינן מתרחשות כאשר אנשים עדים לטעויות שהכלי מבצע (Banks et al., 2018). לעיתים אף קורה ההפך: כאשר אנשים שהתנדבו להשתתף במחקר התבקשו לבצע משימה מסוימת בעזרת כלי בינה מלאכותית, הם ניגשו למשימה בהתלהבות רבה. אבל כאשר נתקלו בטעות של הכלי, האמון שלהם ירד באופן חד, והם העדיפו לסגת ממנו ולהסתמך רק על חשיבה אנושית, גם במחיר של טעויות נוספות (Dietvorst et al., 2015). נוסף על כך, כאשר המשתמש הוא מומחה בביצוע המשימה, ותופס את יכולותיו לבצע אותה כגבוהות, קיימת נטייה להתעלם מהצעות הכלי ואף להימנע משימוש בו, גם במחיר של טעויות אנוש; בעוד שאנשים שאינם מומחים יסכימו לקבל את הצעות הכלי ולהסתמך עליהן (Lee & Moray, 1994).³

תוצאות המחקרים שתוארו כאן מצביעות על דגם שבו המשתמש מתחיל באמון בכלי הבינה המלאכותית, וכאשר הוא פוגש בטעות של הכלי, חלה ירידה באמון (איור 2). בתהליך כזה יש השפעה של שני רכיבים על האמון:

1. גודל הטעות שביצע הכלי: ככל שהטעות ניכרת וחשופה יותר, כך יגדל חוסר האמון.
2. (Dzindolet et al., 2003) לתפיסתו של המשתמש את יכולותיו בהשוואה למכונה: כאשר המשתמש מומחה יותר בביצוע המשימה – טעות של הכלי תגרום לירידה באמון שלו.

ירידה באמון בכלי הבינה המלאכותית כתוצאה מטעות מובילה לתופעה המכונה חוסר סבילות לטעות. כלומר, אנשים החווים טעות של כלי AI, אחרי שנתנו בו אמון רב, נוטים פחות להכיל טעויות של הכלי או למצוא דרכים להתמודד איתן, ומצב כזה כבר קשה לתקן.



איור 2: כאשר אנשים עדים לטעות שכלי AI ביצע, האמון שלהם בכלי יורד עד כדי חוסר אמון מוחלט

3. חלק מהמחקרים המוזכרים במאמר נערכו כבר לפני כשלושים שנה. אומנם אז טרם פותחו מודלים מורכבים כמו מודלי שפה, אולם היו אמצעים שנעשה בהם שימוש במכונות לומדות שגם בעבורן היו נחוצים יחסי אמון בין אדם למכונה. לדוגמה, עוד בשנות השישים של המאה הקודמת שולבו רובוטים בתעשיית המכוניות.

התוצאות ללא בדיקה. כמו כן, הסברים דלים מדי או מבלבלים עלולים לגרום לדחיית השימוש באלגוריתם (Kaur et al., 2020).

דרך נוספת לייצר שקיפות היא בניית מדד ביצועים: משווא סיון לאופן שבו ביצע הכלי את המשימה, מעין מטה-מידע על ביצוע. באופן מיטבי, רצוי שמדד הביצועים יהיה מתמשך, לכל אורך ביצוע המשימה ולא רק בסימומה. בדרך זאת המשתמש מקבל תמונה טובה יותר של היכולות המצוינות של הכלי בזמן אמת (Wang et al., 2009). תוצאות מחקרים מעלות שסוג המטה-מידע משפיע על אופן המשתמשים (Seong & Bisantz, 2008): כשמתחילים בניסוי מקבלים מטה-מידע על רמת אמינות נמוכה של הכלי, הם מעידים על רמת אמונה גבוהה בו; כלומר, מטה-מידע על רמת אמינות נמוכה מעודד אמונה יתר. לעומת זאת, מטה-מידע על רמת אמינות גבוהה בכלי גורם להיעדר אמונה. ייתכן שהסיבה לכך טמונה באופן שבו מוצגות הציפיות מהכלי: במקרה הראשון המשתמשים מקבלים מראש אזהרה על אפשרות טעות, כך שהם ערוכים לזהות את הטעות כשתרחש, ולכן היא אינה מערערת את תחושת האמינות של הכלי. במקרה השני, מוצג מידע חיובי המחזק ציפיות בלתי מציאותיות של המשתמשים, ולכן כשמתרחשת טעות, היא בלתי צפויה ופוגעת באמונה שלהם בכלי במידה רבה יותר (Seong & Bisantz, 2008).

דרך שלישית ליצירת שקיפות מתבססת על העובדה שהסברים עונים על צורך של המשתמשים בתחושת שליטה. לדוגמה, כאשר ניתנת להם האפשרות להשפיע על אופן קבלת ההחלטות של הכלי, הם נוטים להתייחס אליו ברצינות רבה יותר – גם כאשר הם עדים לטעויות מזדמנות שהוא מבצע. מעניין לציין כי לרמת השליטה עצמה אין השפעה של ממש: אפילו שינויים קטנים שהמשתמשים יכולים לבצע מצליחים לעורר אמונה ולעודד שימוש בכלי (Dietvorst et al., 2018). שליטה כזאת יכולה להתבצע בדרכים שונות, למשל כאשר הכלי פונה אל המשתמש ומעודד אותו לבקש מידע נוסף או הסברים, אם הוא מעוניין בכך (Buxcinca et al., 2021).

דינמיקה של שליטה

יכולתו של המשתמש לשלוט בהחלטה מגבירה את ערנותו לפלט של הכלי ומעודדת בקרה. שליטה דינמית – פעם של האדם ופעם של האלגוריתם – יכולה לשמר את הערנות לאורך המשימה (Chavallaz et al., 2016), כך שהאדם בביצועי האלגוריתם לא יוביל לקבלה עיוורת של פעולתו, ולא לחשדנות בשימוש בו. כך, למשל, אפשר שפעם האדם ייקח את השליטה ופעם יעניק אותה למכונה, גישה הנקראת "התאמת הקצאה"; או שחלוקת השליטה תיקבע באופן אוטומטי, גישה הנקראת "הקצאה מותאמת". שיקול סביר מאוד המנחה את ההקצאה על השליטה יכול להיות על פי קושי בביצוע המשימה: יש חלקים במשימה שקל למשתמש לבצע ואילו המכונה מתקשה בהם⁴, וחלקים שקשה למשתמש לבצע אך קלים למכונה. לרוב, האדם בביצועי המכונה גבוה כאשר מדובר במשימות חישוביות, אפילו אם המשתמשים עדים לטעויות של האלגוריתם (Dijkstra, 1999), ונמוך כאשר מדובר במשימות חברתיות ורגשיות (Lee, 2018). כדי ליצור חלוקה מיטבית בין האדם למכונה אפשר, למשל, שהתאמת ההקצאה תתבצע כך

שהמשתמש ישמור לעצמו את כל המשימות שנראות לו קלות יחסית, ויפנה לאלגוריתם את המשימות שהוא מחשיב כקשות. בהקצאה מותאמת, אפשר שהמכונה תשנה מדי פעם את מידת הקושי של המשימה המוקצית למשתמש (קלה עד בינונית), כדי לשמור על ערנותו. לדוגמה, במגדלי פיקוח בשדות תעופה מקובל שבינה מלאכותית מקצה את המסלולים וקובעת את המרחק בין המטוסים השונים בנחיתות והמראות, אבל לפקחי הטיסה יש אפשרות לטול את השליטה על ההקצאות במקרה שהם מגלים שהמרחק בין הטיסות אינו מרווח דיו.

כיצד המחקר על אופן כללי בניה מלאכותית יכול לעזור בתכנון משימות לתלמידים?

בדומה לנאמר במאמר, המטרה היא לטפח בקרב תלמידים שימוש נכון בכלי בניה מלאכותית – כזה המבוסס על ערנות ליכולות של הכלים ולטעויות שהם עלולים לבצע, לצד יכולת להמשיך ולתקשר עם הכלי לצורך שיפור התוצר.

לשם כך חשוב לאפיין את התפיסות האפשריות של התלמידים בנוגע לאופן בניה מלאכותית. אומנם המאמר מתאר יחסי אופן בין אנשים בוגרים לבין כלי בניה מלאכותית, אבל ברוח המאמר אפשר לאפיין שתי תפיסות מנוגדות:

1. סביר שיש תלמידים התופסים את יכולות המכונה כטובות הרבה יותר מאלו של עצמם, כולל היבטים של מהירות בביצוע המשימה והשקעת מאמץ חשיבה. כתוצאה מכך הם נותנים בכלי אופן רב יותר, ואינם מחפשים עדויות תומכות נוספות להמלצה של הכלי או לפלט שהתקבל ממנו.

2. סביר שיש תלמידים שנתקלו בעבר בטעות של הכלי שגרמה לידיה משמעותית באופן בו⁵. כתוצאה מכך הם מעדיפים לסגת מהשימוש בו ולהסתמך רק על חשיבה אנושית, גם במחיר של טעויות נוספות שהם עצמם עלולים לבצע.

כדי לקרב כל אחת מהתפיסות הללו לתפיסה שמגלמת ערנות לביצועי הכלי, אפשר להיעזר בדרכים שהוצעו במאמר לשיקום האופן בכלי בניה מלאכותית:

א. מטה-מידע על רמת אמינות נמוכה של הכלי מעודד אופן יתר, ואילו מטה-מידע על רמת אמינות גבוהה בכלי גורם להיעדר אופן.

ב. שינויים, אפילו קטנים, שהמשתמשים יכולים לבצע בתוצאות של הכלי מצליחים ליצור תחושת שליטה, לשפר את האופן בכלי ולעודד שימוש בו. לדוגמה, פנייה של הכלי למשתמשים לבקש מידע נוסף או הסברים אם הם מעוניינים בכך.

ג. המשתמשים יכולים לשמור לעצמם את המשימות שנראות להם קלות, יחסית, ולהפנות לאלגוריתם את המשימות שהם מחשיבים כקשות.

כאמור, השפעת ההתערבות הללו על שיקום האופן בכלי AI אופייני בעיקר בקרב מבוגרים, ויש לבדוק כיצד הן משפיעות על תלמידים. בכל מקרה, גם אם השפעתן על תלמידים היא שונה מהשפעתן על מבוגרים, אפשר להשתמש בהן כדי לפתח את הערנות ביחסי האופן בין התלמידים לבין AI.

4. לרוב, האלגוריתמים מתקשים לבצע משימות שאי-הוודאות הסטטיסטית בהן גדולה בהקשר של ניבוי מסוים.

5. יש עדויות לכך שכאשר הלמידה מתבצעת מול כלי AI שאף בודק ומעריך את עבודתו של התלמיד, אופן התלמידים בכלי מושפע מאוד מהציון שהכלי נותן להם (Conijn et al., 2023) ופחות מהתערבויות אחרות.

הצעה למשימה המפתחת ערנות לתוצרי בינה מלאכותית בקרב תלמידים

במשימה זאת אתם מתבקשים לשוחח עם מחולל טקסט (לדוגמה GPT, Gemini, Cloud) כדי לקבל ממנו תוצר (תשובה לשאלה, ציור). לרשותכם [רשימת הכלים המאושרים על ידי משרד החינוך](#).

שימו לב: ייתכן שהכלי ייתן לכם תשובה שיש בה טעות או שאינה מותאמת למה שציפיתם ממנו!

חלק א': תרגול אישי בתחום שבו אתם מרגישים מומחים

1. כיתבו מְנָחָה (prompt) במחולל טקסט לבחירתכם:

נסחו שאלה או בקשה לתוצר בנושא שאתם מומחים בו (אומן שאהוב עליכם, ענף ספורט שאתם עוקבים אחריו, תחביב אומנותי שלכם, אג'נדה חברתית שחשובה לכם).



2. בדקו את התוצר שקיבלתם:

א. ממה אתם מרוצים?

ב. ממה אתם פחות מרוצים?

ג. האם אתם מזהים טעות, אי-דיוק או הטיה בתשובה? אם כן – מהם?

3. בדקו את תהליך החשיבה של הכלי:

א. בקשו מהכלי להסביר לכם על סמך אילו עדויות או נתונים הוא יצר את התוצר שקיבלתם ממנו.

ב. האם ההסבר שלו משכנע אתכם? מדוע?

למורה: שימו לב שהיום כבר יש אפשרות לבקש שקיפות של תהליך החשיבה של הכלי (לדוגמה, באמצעות כפתור ייעודי ב-GPT).

4. נסו לעזור לכלי לשפר את התוצר:

א. שאלו את הכלי מה הוא מעוניין לדעת כדי לשפר את התוצר שביקשתם.

ב. ספקו לכלי את המידע שביקש.

ג. בקשו מהכלי תוצר חדש. האם הוא אכן השתפר? במה?

5. בדקו מה לימדה אתכם המשימה:

א. מה למדתם על הדרך שבה כלי בינה מלאכותית עובד?

ב. אם הייתם משתמשים בכלי כזה בתחום שאינכם מתמצאים בו – מה לדעתכם חשוב לבדוק או לעשות?

למורה:

א. יש לנסח משימה בתחום התוכן הנלמד כעת בכיתה (לדוגמה: נשימה תאית, יחסי טורף-נטרף, סוכרת), שאותה יבצעו התלמידים באמצעות כלי AI. המשימה יכולה להיות מענה לשאלה פתוחה העוסקת בתכנים; קביעת עמדה בנושא מדע-חברה; יצירת חיבור קצר בעד ונגד פעולה או החלטה מסוימת; או כל משימה שאתם נוהגים לתת לתלמידים כחלק מהלמידה ואפשר לענות עליה בדרכים רבות (לא שאלות שלהן תשובה נכונה אחת).

ב. יש ליידע את התלמידים מראש כי יידרשו לייצר העתק של שיחתם עם הכלי. יצירת העתק של שיחה שונה בכלים שונים, ולעיתים יכולה להיות בעייתית. במקרה שאין אפשרות כזאת בכלי, אפשר לבצע צילומי מסך.

1. הכינו את עצמכם למשימה:
 - א. אילו חלקים במשימה אתם יכולים לבצע בעצמכם?
 - ב. באילו חלקים של המשימה תוכלו להיעזר בכלי ה-AI?
2. בצעו את המשימה:
 - א. בצעו את חלקי המשימה המתאימים לכם.
 - ב. הציגו לכלי את חלקי המשימה המתאימים לו לדעתכם.
3. בהנחה שהתוצר שקיבלתם עלול להכיל טעויות שקשה לכם לזהות, נסו לשפר את התוצר:
 - אילו שאלות כדאי לשאול את הכלי כדי לשפר את התוצר? השתמשו, במידת הצורך, בשאלות מחלק א' של המשימה.
4. המשיכו את שיחתכם מול הכלי עד שהתוצר ישתפר לפי דעתכם.
5. מזגו בין ביצועי הכלי לבין ביצועיכם:
 - שלבנו בין התוצר שביצעתם עצמאית לבין התוצר שקיבלתם מכלי ה-AI והגישו למורה את התוצר יחד עם העתק השיחה שלכם עם הכלי.
6. בדקו מה לימדה אתכם המשימה:
 - א. באיזה אופן עזר לכם הכלי לבצע את המשימה?
 - ב. במה תרמתם בעצמכם לשיפור התוצר?

למורה:

בסיום המשימה רצוי שהתלמידים ישתפו את התובנות שלהם במליאה: מה הם למדו על הדרך שבה כלי בינה מלאכותית כמו מחולל טקסט עובד? מה לדעתם חשוב לעשות כאשר התחום שבו הם זקוקים לעזרת הכלי אינו תחום ההתמחות שלהם, כמו תכנים בביווגיה? אם מעוניינים בכך, אפשר לערוך על הלוח רשימת תובנות כיתתית שתהיה כלי מנחה לעבודה עם כלי בינה מלאכותית.

- Banks, V.A., Eriksson, A., O'Donoghue, J. & Stanton, N.A. (2018): "Is partially automated driving a bad idea? Observations from an on-road study". **Applied ergonomics 68**: pp. 138–145.
- Bansal, G., Wu, T., Zhou, J., Fok, R., Nushi, B., Kamar, E., Ribeiro, M.T. & Weld, D. (2021): "Does the whole exceed its parts? The effect of AI explanations on complementary team performance". **In: Proceedings of the 2021 CHI Conference on Human Factors in Computing Systems**, pp. 1–16.
- Buxcinca, Z., Malaya, M.B. & Gajos, K.Z. (2021): "To trust or to think: cognitive forcing functions can reduce overreliance on AI in AI-assisted decision-making". **Proceedings of the ACM on Human-computer Interaction 5**: pp. 1–21.
- Castelfranchi, C. (1998): "Modelling social action for AI agents". **Artificial Intelligence 103**: pp. 157–182.
- Castelfranchi, C. & Falcone, R. (2000): "Trust and control: A dialectic link". **Applied Artificial Intelligence 14**: pp. 799–823.
- Chavaillaz, A., Wastell, D. & Sauer, J. (2016): "System reliability, performance and trust in adaptable automation". **Applied ergonomics 52**: pp. 333–342.
- Conijn, R., Kahr, P. & Snijders, C.C.P. (2023): "The Effects of Explanations in Automated Essay Scoring Systems on Student Trust and Motivation". **Journal of Learning Analytics 10(1)**: pp. 37-53. <https://doi.org/10.18608/jla.2023.7801>
- Dijkstra, J.J. (1999): "User agreement with incorrect expert system advice". **Behaviour & Information Technology 18**: pp. 399–411.
- Dietvorst, B.J., Simmons, J.P. & Massey, C. (2015): "Algorithm aversion: people erroneously avoid algorithms after seeing them err". **Journal of experimental psychology: General 144**: p. 114.
- Dietvorst, B.J., Simmons, J.P. & Massey, C. (2018): "Overcoming algorithm aversion: people will use imperfect algorithms if they can (even slightly) modify them". **Management Science 64**: pp. 1155–1170.
- Dietvorst, B.J. & Bharti, S. (2020): "People reject algorithms in uncertain decision domains because they have diminishing sensitivity to forecasting error". **Psychological science 31**: pp. 1302–1314.
- Dzindolet, M.T., Peterson, S.A., Pomranky, R.A., Pierce, L.G. & Beck, H.P. (2003): "The role of trust in automation reliance". **International Journal of Human-Computer Studies 58**: pp. 697–718.
- Kaur, H., Nori, H., Jenkins, S., Caruana, R., Wallach, H. & Wortman Vaughan, J. (2020): "Interpreting interpretability: understanding data scientists' use of interpretability tools for machine learning". **In: Proceedings of the 2020 CHI Conference on Human Factors in Computing Systems**, pp. 1–14.
- Kelly, S., Kaye, S.A. & Oviedo-Trespalcacios, O. (2023): "What factors contribute to the acceptance of artificial intelligence? A systematic review". **Telematics and Informatics 77**: Article 101925.
- Lee, J. & Moray, N. (1992): "Trust, control strategies and allocation of function in human-machine systems". **Ergonomics 35**: pp. 1243–1270.
- Lee, J.D. & Moray, N. (1994): Trust, self-confidence, and operators' adaptation to automation. **International Journal of Human-Computer Studies 40**: pp. 153–184.
- Lee, M.K. (2018): "Understanding perception of algorithmic decisions: fairness, trust, and emotion in response to algorithmic management". **Big data & society 5**: 2053951718756684.
- Logg, J.M., Minson, J.A. & Moore, D.A. (2019): "Algorithm appreciation: people prefer algorithmic to human judgment". **Organization Behavior and Human Decision Process 151**: pp. 90–103.
- Manzey, D., Reichenbach, J. & Onnasch, L. (2012): "Human performance consequences of automated decision aids: the impact of degree of automation and system experience". **Journal of Cognitive Engineering and Decision Making 6**: pp. 57–87.
- Pazouki, K., Forbes, N., Norman, R.A. & Woodward, M.D. (2018): "Investigation on the impact of human-automation interaction in maritime operations". **Ocean Engineering 153**: pp. 297–304.
- Seong, Y. & Bisantz, A.M. (2008): "The impact of cognitive feedback on judgment performance and trust with decision aids". **International Journal of Industrial Ergonomics 38**: pp. 608–625.
- Thielmann, I. & Hilbig, B.E. (2015): "Trust: an integrative review from a person- situation perspective". **Review of General Psychology 19**: pp. 249–277.
- Wang, L., Jamieson, G.A. & Hollands, J.G. (2009): "Trust and reliance on an automated combat identification system". **Human Factors 51**: pp. 281–291.
- Zerilli, J., Knott, A., Maclaurin, J. & Gavaghan, C. (2019): "Algorithmic decision-making and the control problem". **Minds and Machines 29**: pp. 555–578.



מותר להוציא ניידים

קישורים שעוזרים לנו להכיר את הבינה המלאכותית

כאן 11, המעבדה - הסכת (פודקאסט)

[מה מבינה הבינה?](#)



[בינה מלאכותית תחליף את בני האדם?](#)



ידיעה מתוך שבוע טוב ביולוגי

[עיבוד תנועה במוח: ביולוגיה כמקור השראה לבינה מלאכותית](#)



כתבות מהידען

[הזיות AI](#)



[ההיסטוריה של הבינה המלאכותית](#)



סרטוני הסבר על AI

[סרטון על רשתות נוירונים מלאכותיות \(באנגלית עם כתוביות בעברית\)](#)



[סרטון באנגלית עם כתוביות בעברית](#)



[סרטון באנגלית](#)



תקציר עבודת מחקר

האם בינה מלאכותית נתונה ללחץ חברתי?



נקודת מבט מעניינת על הנטייה של מודלי שפה להתמקד בחוות דעתם של רוב המומחים למרות שהעדויות מראות שהם טועים.

[עבודת מחקר בנושא](#) הוגשה למוזיאון המדע על ידי תלמיד בבית הספר הכפר הירוק ע"ש לוי אשכול ברמת השרון, והיא מסתמכת על [מאמר מחקר](#) של קבוצת חוקרים ישראלית ממכללת עמק יזרעאל ואוניברסיטת חיפה. תודה למורה הדס גרדי מהכפר הירוק על השיתוף.

חשוב לציין, שכלי בינה מלאכותית אומנו להתמקד בדעת מומחים משום שלרוב היא אמינה, בוודאי כאשר דעותיהם של מומחים רבים דומות. אבל אפשר לבקש מהכלי במפורש להתמקד בעדויות ואז גדל הסיכוי שהתוצר יהיה יותר מותאם להן.





פיתוח כלי להערכה אוטומטית של תשובות לשאלות פתוחות

שילוב עקרונות פדגוגיים עם למידת מכונה

מוריה אריאלי, המחלקה להוראת המדעים, מכון ויצמן למדע

מעצבת - לבין מגבלות הזמן והמשאבים המאפיינות את ההוראה בפועל. מעבר לכך, כלים אוטומטיים כאלה יכולים לפנות את המורים מההתעסקות הטכנית והמייגעת שבהערכה, ולאפשר להם להתמקד בתהליכים עמוקים ומשמעותיים יותר בתהליך ההוראה והלמידה בכיתתם.

במאמר זה אציג כלי אוטומטי להערכת תשובות פתוחות בביווגיה, שפיתחנו במחלקה להוראת המדעים במכון ויצמן למדע, בשיתוף פעולה של שתי קבוצות מחקר: קבוצת "ביווגיה" בראשותה של פרופ' ענת ירון וקבוצת "גישות חינוכיות בניתוח למידה" בראשותו של ד"ר גיורא אלכסנדרון. הכלי שפיתחנו מבוסס על למידת מכונה - אחת השיטות המרכזיות בתחום הבינה המלאכותית.

מהם המאפיינים של הסברים מדעיים?

כדי להבין כיצד פיתחנו את הכלי, יש להכיר תחילה את המאפיינים העמוקים של הסבר מדעי.

הסברים מדעיים הם אחד מרכיבי הליבה בהבנת תופעות ביווגיות. במסמך "דמות הבוגר 2030" נכתב כי היכולות להסביר תופעות מדעיות, לנסח טיעון מבוסס ולהבחין בין הסברים מדעיים לבין אלה שאינם כאלה הן מיומנויות ליבה באוריינות מדעית. בהתאם לכך, גם בספרות המקצועית בתחום הוראת המדעים נטען כי ניסוח של הסבר מדעי דורש מהתלמיד לא רק ידע, אלא גם יכולת לקשור בין עקרונות, לזהות קשרים סיבתיים ולהציג מנגנון המסביר את התהליך, ולא רק מתאר אותו. הסברים אלו אינם רק מדד להבנה עמוקה - הם גם כלי ללמידה עצמה: תהליך הניסוח והבנייה של הסברים תורם לגיבוש החשיבה המדעית של הלומד, ולכן יש לו ערך פדגוגי מהותי (de Andrade et al., 2019; Krist et al., 2019).

לא כל תשובה של תלמיד נחשבת להסבר מדעי. מטרתם של הסברים מדעיים להסביר למה או איך תופעה מסוימת התרחשה, ולכן הם מבוססים על קשרים סיבתיים ו / או מנגנוניים בין רכיבים במנגנון, תוך שימוש בעקרונות ומושגים מדעיים ומעבר בין רמות ארגון שונות.

מבנה ההסבר המדעי כולל שני חלקים עיקריים: (1) תיאור של התופעה - מה קרה או מה צפוי לקרות ("What" part), למשל, "עליית הטמפרטורה הובילה לירידה בקצב פעילות האנזים"; ו-(2) הצגה של הסיבות או הגורמים המסבירים איך או למה התופעה התרחשה ("How / Why" part), למשל "בטמפרטורה גבוהה חל שינוי במבנה המרחבי של האנזים (חלבון), אשר גורם לשינוי במבנה האתר הפעיל. כתוצאה מכך, פוחתת ההתאמה

מורים בכלל, ומורי ביווגיה בפרט, מתמודדים עם שלל אתגרים בהוראה, כגון: עומס של תכנים מדעיים מורכבים ומשתנים בקצב מהיר, שמירה על רלבנטיות ועדכניות, התמודדות עם כיתות הטרוגניות, יצירת מעורבות של תלמידים בנושאים מדעיים-ערכיים ועוד. בתוך כלל האתגרים הללו בולטים במיוחד תחומים שיש בהם פער בין שאיפה לבין היכולת המעשית לממש אותה. אחד מהאתגרים הללו הוא ביצוע הערכה המקדמת למידה, ולא רק לשם מדידה (כלומר, לא רק ציון). הדבר מצריך ליווי ומתן משוב אישי לתלמידים אחרי כל אירוע הערכה, מה שיכול לאפשר הוראה ולמידה המותאמות לכל תלמיד ותלמידה.

למשוב הניתן במהלך הלמידה (הערכה מעצבת), ולא רק בסופה (הערכה מסכמת), יש תפקיד קריטי בהעמקת ההבנה של התלמיד ובשיפור איכות התשובה שלו. מחקרים מראים כי משוב ממוקד ומיידי עשוי לשפר לא רק את התוצר הסופי, אלא גם את תהליך החשיבה המוביל אליו (Tansomboon & Linn, 2016; et al., 2017) גם בהקשר של הסברים מדעיים שתלמידים יוצרים כתשובה לשאלה פתוחה, משוב המצביע על רכיבים חסרים, חוסר קשר סיבתי או אי-דיוק מושגי - מאפשר לתלמידים לבחון מחדש את תפיסותיהם ולדייק את הבנתם. משוב כזה, כאשר ניתן באופן מותאם ואישי, יכול לשנות מהותית את איכות הלמידה ולהוביל לשיפור של כישורי ההסבר וההבעה בכתב. כדי לבצע הערכה מעצבת איכותית, מורים מתבקשים ללוות כל תלמיד בהתאם לדרכי החשיבה הייחודיות שלו, לזהות פערי הבנה בזמן אמת, ולהציע תמיכה מדויקת המקדמת הבנה עמוקה.

אלא שהמציאות בכיתה שונה. מורים רבים מעידים כי בעומס השגרה, משוב כזה ניתן רק לעיתים רחוקות, אם בכלל. התוצאה: תלמידים לא תמיד מבינים מה חסר בתשובתם, וחלקם לא מצליחים לשפר את הסבריהם באופן מהותי. נוסף על כך, מורים נדרשים להתמודד עם עשרות תשובות פתוחות, הכוללות לא פעם בליל של טיעונים, תיאורים והצהרות לא מדויקות. כדי להבחין בין הסברים איכותיים לבין כאלה שאינם מדויקים, נדרשים הבנה עמוקה של הסברים מדעיים שונים, מומחיות בבניית מחוונים וזמן לבצע את הבדיקה בצורה איכותית ויסודית.

אחד התחומים שבהם ניכרת תרומה משמעותית לצמצום הפער בין הרצוי למצוי בנתינת משוב לתלמידים הוא הערכה אוטומטית של תשובות פתוחות. טכנולוגיות אלו, כאשר הן מבוססות על הבנה פדגוגית עמוקה ועל מחווני תוכן מדויקים, יכולות לספק לתלמידים משוב אישי בזמן אמת, ולמורים - תמונה עשירה של דרכי החשיבה בכיתה, וכל זאת במהירות ובפשטות (Ariely et al., 2024). כך אפשר להתחיל לגשר על הפער שבין השאיפה להוראה מותאמת אישית ומתן הערכה

של המורים לתכנן הוראה ולמידה מותאמות אישית. הכלי אינו מעריך תשובות לפי כללים קבועים מראש בלבד, אלא אף "לומד" מדוגמאות, מזהה תבניות חדשות, ומגיב באופן מותאם לכל תלמיד ותלמידה. בכך הוא מממש בפועל יכולות שנחשבו בעבר לאנושיות בלבד - כמו ניתוח, הסקה ומתן משוב איכותני. זהו שימוש מתקדם בבניה מלאכותית בהוראה, התורם לקידום אחד מייעדיה המרכזיים.

כדי לפתח כלי המסוגל להעריך הסברים מדעיים של תלמידים בצורה אוטומטית, עלינו קודם כולל למד את המחשב איך לתת משוב כמו מורים מומחים בביולוגיה ובהערכה. תהליך ה"לימוד" של המחשב (המכונה) נקרא אימון, והוא דומה במידה מסוימת להוראה. אנחנו מציגים למחשב דוגמאות רבות של תשובות תלמידים, ומסבירים לו מה נכון או שגוי בכל אחת מהן. תהליך זה נקרא "תיוג של דוגמאות": אנו מספקים למחשב מאות רבות של דוגמאות מתויגות, כלומר כאלה שלצידן מופיעה ההערכה - "זו תשובה נכונה", "זו שגויה", "זו חלקית", או "כאן מופיע רעיון מסוים וכאן לא" (למשל: האם התלמיד ציין מנגנון ביולוגי? האם יש קשר סיבתי? או האם יש שימוש מדויק במונחים? ראו מסגרת: מהם המאפיינים של הסברים מדעיים?). באמצעות הדוגמאות הללו, המחשב לומד לזהות דפוסים ולגבש מודל - כלומר, מערכת חוקים ופעולות (אלגוריתמים) המסוגלת להעריך תשובות חדשות באופן דומה למורה אנושי.

אימון המודלים ובדיקת המהימנות שלהם מצריכה שילוב כוחות בין שני מומחי תוכן: האחד, מומחה בחקר הוראת הביולוגיה וההערכה, שתפקידו להגדיר את הרכיבים המרכזיים בכל תשובה, רמת הדיוק, עומק ההסבר. אלה מובילים לבניית מחוון פדגוגי עשיר, מותאם למטרות ההוראה והלמידה, ואשר מתאר מה באמת נדרש מתלמיד כדי לתת הסבר טוב. שלב יצירת המחוון ותיוג הדוגמאות הוא קריטי, מכיוון שהוא זה המשמש בסיס ללמידת המכונה; השני, מומחה מתחום מדעי המחשב, אשר בתום תהליך התיוג מבצע את שלב האימון, מעבד את הנתונים המתויגים ובונה מודל אשר לומד לזהות את הרכיבים הללו בתשובות חדשות.

לבסוף, כדי לבדוק עד כמה המודל מדויק, מציגים לו תשובות חדשות, משווים את הערכותיו להערכה של מעריכים אנושיים (מומחי תוכן מהוראת הביולוגיה) לתשובות אלה, ובוחנים את רמת ההסכמה בין המעריכים האנושיים לבין ההערכה שביצע המודל. ככל שרמת ההסכמה גבוהה יותר, כך אפשר לסמוך יותר על אמינות הכלי.

בין האתר הפעיל לסובסטרט, מה שמוביל לירידה ביכולת הקישור שלהם - ולירידה בקצב יצירת התוצר". יש לשים לב כי רכיב ה"איך / למה" הוא חלק הכרחי על מנת שתשובת התלמיד תיחשב להסבר, שכן הוא המבדיל בין הסבר מדעי לבין משפט תיאורי. תשובות שאינן כוללות את רכיב ה"איך / למה" אינן נחשבות להסבר (Alameh et al., 2022).

היכולת לזהות את המאפיינים העמוקים הללו של הסברים מדעיים בתשובות של תלמידים חיונית לבניית מחוונים מדויקים, ולגיבוש קריטריונים להערכת עומק החשיבה המדעית שלהם. כך למשל, כדי לענות על השאלה הבאה (נקרא לה מעתה "שאלת עישון"), יש לכלול בהסבר את השרשרת הסיבתית שמובילה מהיקשרות של פחמן חד-חמצני (CO) להמוגלובין, דרך ירידה ביכולת נשיאת החמצן, ועד לפגיעה בביצוע מאמץ גופני. כל שלב בשרשרת מוביל לשלב הבא אחריו. אולם תיאור רצף של שלבים אינו מספיק. כדי שההסבר ייחשב למנגנוני, יש לקשור בין שלבי השרשרת באמצעות קשרים סיבתיים המסבירים לא רק מה קרה אלא גם איך.

אנשים מעשנים סובלים מקושי בביצוע פעילות גופנית. בסיגריה מספר חומרים מזיקים, ביניהם הגז CO (פחמן חד-חמצני). הגז CO המשתחרר בעת עישון הסיגריה הוא בעל נטייה חזקה (גבוהה פי 250 מזו של החמצן) להיקשר להמוגלובין.

הסבירו כיצד נוכחות גבוהה של הגז CO מסבירה את הקושי של אנשים מעשנים לבצע פעילות גופנית.

את ההסבר הרצוי אפשר לייצג באמצעות תרשים (איור 1): כל שלב בהסבר הוא רכיב במחווון, ואפשר להעריך אם הוא קיים בתשובת התלמיד, ואם הוא מדויק, שגוי או חסר.

איך יוצרים כלי הערכה אוטומטית להסברים מדעיים?

כלי הערכה איכותיים הם רכיב הכרחי בלמידה משמעותית, במיוחד כאשר מדובר בשאלות פתוחות המצריכות הסבר מדעי. ככל שהשאלות עמוקות ומורכבות יותר - כך גדל הקושי בהערכתן. התמודדות זו הופכת משמעותית במיוחד בהוראת הביולוגיה, המדגישה הבנה של תהליכים, קשרים סיבתיים ושימוש מדויק במושגים מדעיים.

לאור זאת, פיתחנו כלי הערכה אוטומטי חדש, המשלב עקרונות פדגוגיים עם טכנולוגיות מתקדמות של למידת מכונה. הכלי מאפשר מתן משוב אישי לתשובות פתוחות של תלמידים - ואף זיהוי דפוסי חשיבה רחבים בכיתה, באופן המרחיב את יכולתם



איור 1: רכיבי ההסבר לשאלת העישון



הנבדקות אוטומטיות מציעות גם הדרכה בכתיבת הסברים מדעיים, כך שהמשימה מתרכזת לא רק בתוכן ההסברים במשימה אלא אף במיומנות כתיבת ההסבר עצמה. שילוב זה מאפשר למורים לקבל בזמן אמת תובנות על הבנת תלמידיהם, לזהות נקודות חוזק או קושי מושגי, ולתכנן תגובות פדגוגיות מותאמות - כל זאת בלי לוותר על מעורבותם הישירה בתהליך, אלא להפך: תוך חיזוק יכולתם לקבל החלטות מושכלות על בסיס מידע איכותי וממוקד.

כלי זה עמד במרכזו של מחקר ראשון מסוגו בישראל, שבו בחנו את איכות הכלי ואת השימוש בו בפרקטיקה בכיתה. אחד הממצאים המרכזיים שעלו מהמחקר נוגע להבנה של מהו הסבר סיבתי איכותי בביולוגיה. הסבר סיבתי אינו מסתפק בתיאור תופעה, אלא מצריך קישור בין שלבים בתהליך, תוך הצגת גורמים ומנגנונים המובילים אליה (קשרים סיבתיים). כדי להסביר תופעה ביולוגית התלמיד נדרש למעשה לפרוש רצף של התרחשויות המקשרות בין תנאים מוקדמים לבין תוצאה, ולשזור בתוכם את המושגים המדעיים הרלבנטיים. הסבר מדעי כזה מחייב דיוק מושגי, הבנה של יחסי סיבה ותוצאה, ויכולת לתאר את **האופן** שבו התרחש התהליך - לא רק את **מה שקרה** בסופו. הכלי שפיתחנו נבנה בדיוק כדי לזהות את הרכיבים הללו בתשובות של תלמידים, ולספק בעבורם משוב המעודד חשיבה סיבתית-מנגנונית, ולא רק שלילת מידע.

נוסף על ההערכה האוטומטית של תשובות התלמידים, נעשה במחקר שימוש בכלי להפקת תובנות רחבות יותר באמצעות ניתוח צברים (Cluster Analysis) של כלל התשובות. ניתוח זה זיהה חמש קבוצות של הסברים, שכל אחת מהן משקפת דפוס מובחן, הקשור לרמת ההבנה המדעית של הלומדים ו / או למיומנות כתיבת ההסבר המדעי שלהם.

את הקבוצות הללו אפשר היה לסדר על פי רצף: בקצה האחד של הרצף מוקמה הקבוצה הראשונה, שכללה תשובות מדויקות שהציגו תיאור נכון של התופעה בצירוף הסבר סיבתי מלא, רציף, מדויק מבחינה מדעית, ובשפה מתאימה. בקצהו השני מוקמה קבוצה של תשובות שלא כללו כלל רכיבים של הסבר - לעיתים הופיע בהן רק משפט כללי או תשובה שאינה רלבנטית לשאלה.

לאחר פיתוח כלי ההערכה האוטומטי, שיכול להעריך תשובות פתוחות של תלמידים בודדים ולספק עבורן משוב אישי - עברנו לשלב הבא: זיהוי דפוסים רחבים בתשובות של תלמידים באמצעות כלי הקרוי גרופר (Grouper), המאפשר למורים לראות את "התמונה הגדולה". הגרופר מבוסס על שיטה מתחום מדעי הנתונים הקרויה יצירת אשכולות (Cluster Analysis), המאפשרת למחשב לגלות תבניות וסגנונות חוזרים בתוך כמויות גדולות מאוד של נתונים. מדובר בתהליך של למידת מכונה בלתי מונחית (Unsupervised) שבו המערכת עצמה מחפשת קבוצות של תשובות הדומות זו לזו, בלי שנגדיר לה מראש מה בדיוק לחפש. לדוגמה, היא עשויה לזהות קבוצה של תלמידים שכתבו הסבר סיבתי אך חלקי, קבוצה אחרת שהשתמשה במושגים ביולוגיים אך בלי לחבר אותם, וקבוצה שלישית שבה התלמידים הסתפקו בתיאור שטחי בלבד. אילו תהליך זה היה מתבצע על ידי מעריך אנושי, הוא היה אורך זמן רב מאוד. כאן נכנס שלב נוסף ומהותי - והוא בחינת הקבוצות שיצר המחשב על ידי מומחה בתחום הוראת הביולוגיה, שתפקידו לנתח את החלוקה שהמחשב מציע ולפרש אותם. לדוגמה: מה מאפיין כל קבוצה? האם הקבוצות חושפות קשיים דומים? אילו רמות הבנה שונות מייצגת כל קבוצה? באמצעות פרשנות זו הופך הכלי לאמצעי להוראה מותאמת אישית, המאפשר למורה לתכנן תגובות פדגוגיות מדויקות, לעצב משימות המשך ואף להתאים הוראה פרטנית לקבוצות תלמידים בעלות מאפיינים דומים.

מהמחקר לפרקטיקה - כלי הערכה אוטומטיים בסביבת "פטל" ביולוגיה


לאחר פיתוח ובדיקה של האלגוריתמים עברנו ליישום הכלים בהקשרי הוראה בפועל. במסגרת זו שולבו האלגוריתמים בפלטפורמת פטל (Petel) ללמידה והוראה מותאמת אישית¹.

בשלב זה התמקדנו בפיתוח והטמעה של שני השימושים המרכזיים, כפי שתוארו בחלק הקודם: הראשון - הפקת משוב אוטומטי על תשובות פתוחות שמגישים תלמידים במשימות דיגיטליות; והשני - מיפוי מושגי ברמת כיתה שלמה של תשובות תלמידים לפי דפוסי חשיבה ורמות הבנה, באמצעות הכלי גרופר (grouper). חשוב לציין כי המשימות שבהן משולבות שאלות

מה ההבדל בין בינה מלאכותית לבין למידת מכונה?

אף על פי שרבים משתמשים במונחים "בינה מלאכותית" (Artificial intelligence) ו"למידת מכונה" (Machine learning) כאילו הם שקולים, חשוב להבין שהם שונים, ויש להבחין ביניהם.

בינה מלאכותית היא שדה מחקרי או תחום רחב שכולל בתוכו את תת-התחום של למידת מכונה. בינה מלאכותית מתיימרת לחקות את הדרך שבה בני אדם חושבים, באופן המאפשר לה לבצע משימות מורכבות של ניתוח, הסקה, למידה. לעומת זאת, בלמידת מכונה המטרה היא לרתום אלגוריתמים כדי ליצור מודלים שביכולתם לבצע משימות מורכבות. במילים אחרות, למידת מכונה היא השיטה או הכלי המעשי שדרכו באה לידי ביטוי בינה מלאכותית.



איור 2: השפעת המשוב של הכלי האוטומטי על איכות ההסברים בתשובות התלמידים

(אשכולות) שימש בסיס לתכנון הוראה דיפרנציאלית. עם זאת, הן ציינו גם את הצורך בלמידה והדרכה שיסייעו להן לפרש את תוצרי הכלי באופן מדויק, כדי לשלב אותם בצורה מיטבית בפרקטיקות ההוראה הקיימות.

לסיכום, השוואה בין קבוצות הניסוי והביקורת הדגישה את תרומתו של המשוב האוטומטי לשיפור ההסברים המדעיים של תלמידים, והראתה את פוטנציאל הכלי לקידום הערכה מעצבת מותאמת אישית גם בתנאים של עומס ומגבלות זמן בכיתה.

המשך הפיתוח לאור תוצאות המחקר

לאור הממצאים מהמחקר הני"ל פותחה משימה בפטל ביולוגיה המבוססת על תהליך דומה, הקרויה ["תאי דם אדומים ואנמיה - מבוא להסברים סיבתיים"](#). המשימה עוסקת בתפקוד תאי הדם האדומים כנשאי החמצן בגוף האדם, ומדגישה את תפקוד החמצן בתהליך הנשימה התאית בהקשר של מחלת האנמיה. המשימה נבנית סביב תופעה ברמת המקור, ומעמיקה בהדרגה דרך רמות הארגון הביולוגי, עד לרמת תפקידו של הברזל בקשירת החמצן להמוגלובין.

נוסף על ההקשר התוכני, אחת המטרות המרכזיות של המשימה היא לשפר כתיבת תשובות סיבתיות. בהתאם לכך, התלמידים נדרשים לתת הסבר בתשובה לשאלה פתוחה. המערכת בודקת את התשובה אוטומטית ונותנת משוב מיידי ומותאם לתשובתם. בשלב זה התלמידים מתבקשים לבצע רפלקציה על תשובתם ולתקן אותה בהתאם למשוב. התלמידים יכולים לקבל משוב מיידי על אופן התיקון שלהם, מכיוון שהם יכולים לראות את ההבדלים במשובים שהם מקבלים בכל פעם שהם כותבים הסבר.

לאחר שכל התלמידים בכיתה עונים על המשימה, המורים מקבלים דו"ח ברמת הכיתה כולה וברמת התלמידים הבודדים.

חלק אחד של הדו"ח עוסק ברמת ההבנה של כלל הכיתה ובאופן ביצוע המיומנויות הנדרשות במשימה, כפי שאפשר לראות מרגע שהתלמידים מגישים את המשימות (איור 3).

בין שתי הקצוות הללו זוהו שלוש קבוצות ביניים: קבוצה אחת כללה תשובות שתיארו את התופעה או את מרכיביה, אך לא כללו קישור סיבתי המסביר כיצד התרחש התהליך; קבוצה שנייה כללה תשובות עם רכיבים של חשיבה סיבתית נכונה, אך חלקית, משום שחסרו אחד התהליכים הרלבנטיים להסבר; והקבוצה השלישית כללה ניסיונות להסביר את התופעה, אך ההסבר התבסס על ידע שגוי או הבנה חלקית ביותר. כך יצרנו אוטומציה של התהליך כולו: תשובה חדשה של תלמיד מוערכת על ידי המודלים לפי המחווה, זוכה למשוב מתאים ומסווגת באופן אוטומטי לאחת מהקבוצות הני"ל. בהתאם, הכלי לא רק מעריך את התשובה עצמה, אלא גם פותח חלון להבנת אופן החשיבה שמאחוריה.

תוצאות המחקר


במסגרת המחקר יושם הכלי להערכה אוטומטית בכמה כיתות ביולוגיה בתיכון, כחלק מתהליך למידה אוטומטי. התלמידים התבקשו לנסח הסברים מדעיים לשאלה בנושא אנמיה (ראו בהמשך), וקיבלו משוב אוטומטי מיידי על תשובתם. לאחר קבלת המשוב הם השיבו על שאלה נוספות, בהקשר דומה (שאלת עישון). ההשפעה של הכלי נבחנה באמצעות השוואה בין שתי קבוצות: קבוצה אחת שקיבלה את המשוב האוטומטי, לעומת קבוצת ביקורת שלא קיבלה כל משוב לאחר כתיבת ההסבר בתשובה לשאלה הראשונה.

הממצאים הראו כי התלמידים שקיבלו משוב (קבוצת הניסוי) שיפרו את ההסברים שלהם באופן מובהק וקיבלו ציון גבוה יותר בשאלת העישון. בדיקת תוכן התשובות הראתה כי התלמידים שיפרו את ההסבר שלהם הן במידת הסיבתיות, הן בדיוק המושגי והן בלוגיקה של הקישור בין רכיבי ההסבר. השיפור היה בולט במיוחד בקרב תלמידים שכתבתם הראשונית הייתה חלקית, מבולבלת או לא מדויקת. מנגד, תלמידים בקבוצת הביקורת לא הראו שיפור דומה, והסבריהם נותרו דומים באיכותם לגרסה הראשונה שכתבו (איור 2).

המורות שליוו את התהליך ציינו כי הכלי סייע להן בזיהוי רמות שונות של הבנה בכיתה, והפלט הוויזואלי של הקבוצות




איור 3: דו"ח למורה ברמת הכיתה בהבנת התכנים ובביצוע המיומנויות בשאלת האנמיה



לאחר בניית שרשרת האירועים, יש להוסיף את הקשרים הסיבתיים המקשרים בין שלב אחד לזה הבא אחריו. בדוגמא שלפניכם: ירידה ברמת החמצן בתאים מובילה לירידה בקצב הנשימה התאית (סיבה – תוצאה). מהי הסיבה שרמות נמוכות של חמצן בתאים מובילות לירידה בקצב נשימה תאית? התשובה היא בקשר הסיבתי המחבר בין שני האירועים הללו: ירידה ברמת החמצן בתאים תביא ליריד בקצב נשימה תאית **כי החמצן הוא מגיב בתהליך הנשימה התאית.**

בהתאם, נררו את הקשרים הסיבתיים למקומות המתאימים בתרשים, כך שיקשרו נכון בין שלב אחד לזה הבא אחריו:



איור 4: הקניה של מיומנות ההסבר הסיבתי-מנגנוני

הראשונה מופיעה פעמיים: תחילה נבדקת היכולת הראשונית של התלמיד לכתוב הסבר, והתלמיד מתבקש לענות על השאלה בהתאם לידע ולמיומנויות שברשותו. בשלב הבא מתבצעת במשימה הקניה ממוקדת של מיומנות ההסבר הסיבתי-מנגנוני, תוך הדגשת הרכיבים המרכזיים שמהם בנוי הסבר איכותי (איור 4).

במשימה משולבות שלוש שאלות פתוחות בנושאים הבאים: (1) הקשר בין אנמיה לקושי בביצוע פעילות גופנית; (2) הקשר בין צריכת ברזל לבין טיפול באנמיה ושיפור היכולות לבצע פעילות גופנית; ו-(3) הקשר בין עישון לבין הקושי לבצע פעילות גופנית (בעקבות שאיפת הגז CO). לשאלות אלה מנגנון ביולוגי דומה, אך תפקידן במשימה שונה. השאלה

מייד לאחר מכן המערכת בודקת אוטומטית את ההסבר הראשוני של התלמיד ונותנת לו משוב מותאם לפי התשובה הראשונה שהגיש. בשלב זה, התלמיד נדרש לבצע רפלקציה על ההסבר הראשוני שלו ולתקן אותו אם הוא מעוניין בכך (כלומר, לענות שוב על שאלת אנמיה). כבר בשלב זה במשימה התלמידים יכולים לראות שיפור בהתאם למשוב שהתקבל. דוגמה לכך אפשר לראות באיור 5.

תלמידה כתבה את התשובה הראשונה הבאה:

תאי הדם האדומים אחראים על הובלת החמצן מהריאות אל תאי הגוף ומכילים הומוגלובין שקושר חמצן. כמות נמוכה של תאי דם אדומים גורמת להפחתה באספקת החמצן לרקמות וזה גורם לעייפות, חולשה וקושי בביצוע פעילות גופנית.

וקיבלה את המשוב הבא:

מרכיב בתשובה	סוג המרכיב הנדרש בתשובה	תוצאה	תיקון תוצאה
קישור בין תאי הדם האדומים ו/או המוגלובין להאכלה (מפקיד תאי דם ו/או המוגלובין)	קשר סיבתי	✓	☐
שינוי בכמות החמצן הנמצאת ב/ מוגלובין ב/ מיעוט לנפח /נפח איברים/ רקמות/ תאים. כל התייחסות לשינויים בכמות החמצן הנמצאת ו/או המוגלובין בנפח ללא התייחסות לרמת הארגון שבה זה מופיע	מרכיב בשחרור הסיבות	✓	☐
ידידה לרמת ארגון התא (חמצן בתאים)	מרכיב בשחרור הסיבות	✗	☐
חמצן הוא מניב ב/ דרוש לעשיית תאית/ אנרגיה	קשר סיבתי	✗	☐
שינוי בשיועור/ קצב העשייה התאית	מרכיב בשחרור הסיבות	✗	☐
שימוש במושג "עשייה תאית"	שימוש במושג	✗	☐
ATP/ אנרגיה היא חומר העשייה התאית	קשר סיבתי	✗	☐
שינוי בכמות/ קצב הסקת אנרגיה/ ATP	מרכיב בשחרור הסיבות	✗	☐
שימוש במושג ATP/אנרגיה	שימוש במושג	✗	☐
אנרגיה/ עשייה תאית מוגבלת ב/ דרושה לפעילות העוררים/ תאי העורר בעת פעילות גופנית	קשר סיבתי	✗	☐

לאחר קבלת המשוב וההקניה בנוגע להסברים סיבתיים התלמידה תיקנה את התשובה שלה כך:

אנמיה היא מצב שבו כמות תאי הדם האדומים בגוף נמוכה מהנורמה. תאי דם אדומים מכילים המוגלובין, חלבון שאחראי על קשירת החמצן והעברתו לרקמות הגוף. כאשר מספר תאי הדם האדומים יורד, פחות חמצן מגיע לתאי הגוף, מה שמוביל לירידת חמצן בדם. שינוי בקצב הנשימה התאית ושינוי בכמות ה ATP. במקרה המתואר, האדם סובל מעייפות ומקושי בביצוע פעולות גופניות. הסיבה לכך היא שתאי הדם האדומים אחראים על הובלת חמצן לרקמות. כאשר יש כמות נמוכה של התאים האלה פחות חמצן מגיע לתאים. והם לא יכולים להפיק מספיק אנרגיה שדרושה לפעילות השרירים ולפעילות הגוף בכלל.

וקיבלה את המשוב הבא:

מרכיב בתשובה	סוג המרכיב הנדרש בתשובה	תוצאה	תיקון תוצאה
קישור בין תאי הדם האדומים ו/או המוגלובין להובלה (מפקיד תאי דם ו/או המוגלובין)	קשר סיבתי	✓	☐
שינוי בכמות החמצן הנמצאת ב/ מוגלובין ב/ מיעוט לנפח /נפח איברים/ רקמות/ תאים. כל התייחסות לשינויים בכמות החמצן הנמצאת ו/או המוגלובין בנפח ללא התייחסות לרמת הארגון שבה זה מופיע	מרכיב בשחרור הסיבות	✓	☐
ידידה לרמת ארגון התא (חמצן בתאים)	מרכיב בשחרור הסיבות	✓	☐
חמצן הוא מניב ב/ דרוש לעשייה תאית/ אנרגיה	קשר סיבתי	✗	☐
שינוי בשיועור/ קצב העשייה התאית	מרכיב בשחרור הסיבות	✓	☐
שימוש במושג "עשייה תאית"	שימוש במושג	✓	☐
ATP/ אנרגיה היא חומר העשייה התאית	קשר סיבתי	✗	☐
שינוי בכמות/ קצב הסקת אנרגיה/ ATP	מרכיב בשחרור הסיבות	✓	☐
שימוש במושג ATP/אנרגיה	שימוש במושג	✓	☐
אנרגיה/ עשייה תאית מוגבלת ב/ דרושה לפעילות העוררים/ תאי העורר בעת פעילות גופנית	קשר סיבתי	✓	☐

איור 5: דוגמה לתהליך משוב שקיבלה תלמידה לתשובותיה



איור 6: חלוקת הכיתה לאשכולות לאחר המענה על שאלת האנמיה

שניתנו. אשכולות אלה, שהתקבלו באמצעות Cluster analysis, מייצגים קבוצות תלמידים הנבדלות בדגם ההסברים שהם כתבו בתשובותיהם (כפי שתואר לעיל): מאשכול א' שבו תלמידים שענו תשובות מלאות ועד אשכול ה' הכולל תלמידים שענו תשובות שגויות או נטולות הסבר.

באיור 6 נראית תמונת הכיתה לאחר המענה הראשוני לשאלת האנמיה. תלמידים שלא ענו על השאלות הפתוחות הם נתונים שהמערכת לא יכולה לסווג ולכן מוצגים בנפרד (באפור בחלק העליון). מתחת לכל אשכול מופיעים שלושה כפתורים המאפשרים למורים להפעיל שיקולים פדגוגיים

השאלה השנייה, בנושא הברזל, בודקת את ההבנת התהליך מכיוון הפוך אך בהקשר דומה: כיצד עלייה בכמות תאי הדם האדומים משפרת את היכולת לבצע פעילות גופנית. השאלה השלישית בוחנת את יכולתו של התלמיד להשליך את מה שלמד על הקשר אחר אך דומה, הנוגע להשפעת העישון (ובפרט גז CO) על היכולת לבצע פעילות גופנית.

לאורך כל התהליך נבנית תמונה אישית של רמת ההבנה של כל תלמיד ותלמידה. בנוסף, מורים יכולים להפעיל את הכלי Grouper, המנתח את כלל התשובות בכיתה ומחלק את התלמידים לאשכולות (Clusters) שונים לפי דפוסי ההסברים



אך בפועל אינן מבוססות על עקרונות חינוכיים, מדדים ברורים או תהליך בדיקה מדעי. לכן חשוב להתייחס אליהם בזהירות, ולזכור שכלי הערכה חכם באמת חייב להתבסס על מומחיות אנושית - תוכנית ופדגוגית - ולא רק על נוסחאות מתחכמות.

כלי הערכה חכם באמת חייב להתבסס על מומחיות אנושית

במיוחד כשמדובר במודלים שנועדו לתמוך בהוראה, חשוב מאוד שתהליך האימון של הכלי והחלוקה לקבוצות אפיון יתבצע בשיתוף פעולה בין מומחי תוכן (ביולוגים) ומומחים פדגוגים (חוקרי הוראת המדעים ומורים בפועל). רק הם יכולים לוודא שהתיוגים מבוססים על הבנה עמוקה של התחום, שהשאלות מתאימות לרמות החשיבה הרצויות, ושההערכה אינה מצטמצמת לקריטריונים טכניים בלבד. גם המעורבות של מורים בתהליך האימון - לא כצרכנים בלבד, אלא כשותפים פעילים - היא קריטית לאמינות הכלי, לרלבנטיות שלו ולערכו הפדגוגי.

ללא שיתוף פעולה כזה אנחנו עלולים להיתקל בבוטים או במערכות אוטומטיות שמציגים את עצמם ככלי הערכה, אך מבוססים על מודלים כלליים ולא מפורשים, לעיתים כאלה שנוצרו לצרכים גנריים כמו שיחה חופשית, ולא לשם הבנה פדגוגית או ניתוח מדויק של תשובות תלמידים. כלים כאלה - כולל אלה המתבססים על בינה מלאכותית גנרטיבית - עלולים להפיק הערכות שנשמעות משכנעות,

בתחילת המשימה. ממצא זה בולט במיוחד לנוכח העובדה ששאלת העישון לא לוותה במשוב, אף שנשאלה בהקשר דומה. כלומר, ניכר כי תלמידים מבצעים העברה של המיומנות בין הקשרים שונים.

חשוב לציין כי הניתוחים השונים, כולל הערכת התשובות והחלוקה לאשכולות, מתבצעים באופן מיידי עם הגשת המשימה, כך שגם המורים יכולים להתרשם בזמן אמת מהסברי התלמידים ומהשינויים שחלו בהם לאורך המשימה. התלמידים, מצידם, שמקבלים אף הם משוב מעצב ומיידי, יכולים בעזרתו לבצע רפלקציה, להעמיק את הבנתם ולשפר את התשובה בהתאם.

איך יודעים שהכלי עובד טוב?

היכולת של המחשב ללמוד מדוגמאות תלויה בגורמים רבים, כמו איכות הדוגמאות, הגיוון שלהן ורמת הדיוק של התיוגים. כמו כל תהליך למידה, גם כאן קיימות מגבלות. המודל לומד רק מהמידע שהוזן לו - ולכן עלול לשקף הטיות של מי שאימן אותו או של מאגרי המידע שעליהם התבסס. בהקשר זה חשוב לזכור שמודלים של בינה מלאכותית, ובמיוחד אלה המשתמשים בלמידת מכונה, מתפקדים לעיתים כ"קופסה שחורה": גם כשאנחנו יודעים אילו דוגמאות הזנו לכלי ואילו תוצאות הוא מחזיר, לא תמיד נוכל לדעת איך בדיוק הוא

שונים: (א) מורים יכולים לבחון מיהם התלמידים הנמצאים בקבוצה וגם להעביר תלמידים מקבוצה לקבוצה אם הם רואים לנכון לעשות זאת (באמצעות הכפתור הימני: מידע המציג את רשימת התלמידים באשכול); (ב) מורים יכולים לעיין במאפיינים של חשיבת התלמידים בכל אשכול (כפתור אמצעי: מידע על מאפייני האשכול); (ג) מורים יכולים להחליט אם להקצות את אותה הפעילות לכל האשכולות, או לבחור בעבור כל אשכול את הפעילות המתאימה לו בהתאם למאפייני הקבוצה (כפתור שמאלי: הקצאת פעילויות). כך לדוגמה, לתלמידים המשויכים לאשכול ב' (תלמידים שאינם מחברים באופן סיבתי בין החלקים בהסבר) אפשר להקצות פעילות ייעודית המתמקדת בחיבור בין חלקי ההסבר (איור 7). לחלופין אפשר לעשות עבודה בקבוצות בכיתה, להזמין תלמידים לשיעור פרטני ועוד, הכול לפי החלטת המורים.

אפשרות מעניינת נוספת היא לבחון את "תנועת" התלמידים בין האשכולות, לפני ואחרי קבלת המשוב, או בעקבות הפעילות הממוקדת שהקצו המורים. למשל, אפשר להשוות בין התפלגות התלמידים באשכולות בתחילת המשימה, כאשר ענו על שאלת האנמיה (איור 6), לבין ההתפלגות בסיומה, כאשר ענו על שאלת העישון (איור 8): אפשר לראות כי בשלב הסופי מספר רב יותר של תלמידים משויך לאשכולות א' ו-ב', בהשוואה למצב

איור 7: משימת המשך המוצעת לתלמידים שאינם מחברים באופן סיבתי בין חלקי ההסבר

איור 8: חלוקת הכיתה לאשכולות בסוף הפעילות, לאחר המענה על שאלת העישון

שהוא אינו שקוף לחלוטין. לכן נדרשת בקרה אנושית, פיקוח של מומחי תוכן, והפעלה מושכלת - מתוך שיתוף פעולה הדוק בין טכנולוגיה לפדגוגיה, ולא מתוך הסתמכות עיוורת. זו בדיוק הסיבה שחשוב לראות במודל כלי תומך ולא מחליף: אמצעי שמלווה את שיקול הדעת הפדגוגי של מורים, אך אינו בא במקומו.

הגיע למסקנתו. הסיבה לכך היא שהאלגוריתם מזהה תבניות מורכבות מאוד, לפעמים כאלו שגם מומחים אנושיים לא היו מזהים, והוא בונה מתוכן מערכת חוקים פנימית שקשה לפענח במדויק. אין בכך כדי לומר שהכלי אינו חכם או מועיל - להפך, לעיתים הוא מצליח לדייק באופן מרשים. אך דווקא משום שהוא "לומד בעצמו", חשוב שנשתמש בו מתוך הבנה

תודה מיוחדת לצוות הביולוגיה מתיכון "עודד", ובמיוחד לקרין הלוי ולדלית אביטל, על שיתוף הפעולה והנתונים שאפשרו את המחקר ואת כתיבת מאמר זה.

האם אפשר לסמוך על הערכת תלמידים באמצעות מכונה?

מהמחקר והעבודה המשותפת עם המורים עלו שתי תובנות עיקריות:

ראשית, גם בין מורים אין הסכמה מלאה, גם אם מדובר במורים מנוסים הפועלים לפי אותו מחוון. זוהי תובנה מהותית, שכן מערכות מבוססות בינה מלאכותית לומדות מהערכות אנושיות, ולכן אין לצפות מהן להסכים תמיד עם כל מורה, בדיוק כמו ששני מורים לא תמיד מסכימים זה עם זה. חוסר ההסכמה אינו פגם, אלא תזכורת לכך שהערכה היא תהליך פרשני - גם כשהוא מקצועי - ולכן תוצאות המודל צריכות להיבחן בהקשר, ולא להידחות רק כי הן שונות מדעתו של מורה מסוים.

שנית, מידת ההסכמה בין הערכות המודל לבין ההערכות האנושיות לא הייתה פחותה ממידת ההסכמה בין המורים עצמם. למעשה, האלגוריתם, שנבנה על בסיס תיוגים מקצועיים ותובנות פדגוגיות, הצליח לחקות את מאפייני השיפוט של המורים בדיוק מרשים. ממצא זה חיזק את ההבנה שלפיה כלי הערכה אוטומטיים, כאשר הם מאומנים היטב על ידי מומחים, עשויים לתמוך בתהליכי הוראה והערכה. לא כמחליפים של שיקול הדעת של מורים, אלא ככלים מעצימים, המרחיבים את יכולתם לפעול בדיוק ובהתאמה אישית - ומהר.

שאלת האמון ותפיסתנו כמורים כלפי כלי הערכה אוטומטיים מבוססי בינה מלאכותית עמדה במוקד ההתעניינות שלנו כאשר התחלנו לעבוד עם מורי ביולוגיה על שילוב כלים כאלה בהוראת ביולוגיה. במסגרת השתלמות מקצועית, ביקשנו לבחון לא רק כיצד אפשר להטמיע את הכלים, אלא גם כיצד לחזק את תחושת השליטה, הבהירות והביטחון שלנו, המורים, בעבודתנו עם מערכות מתקדמות. מערכות אלה מציעות תמיכה משמעותית בעבודת ההערכה, אך מעוררות גם שאלות מקצועיות, פדגוגיות ואתיות מורכבות.

כך למשל, במסגרת מחקר (Nazaretzky et al., 2022), התבקשו שישה מורי ביולוגיה לתייג תשובות פתוחות של תלמידים על פי מחוון מוסכם. לאחר מכן נבחנה מידת ההסכמה של כל אחד מהם עם שאר חברי הקבוצה, וכן עם אלגוריתם מבוסס בינה מלאכותית שאומן מראש להעריך תשובות פתוחות על בסיס אותו מחוון.

ההפתעה הייתה גדולה: מידת ההסכמה בין הערכות האלגוריתם להערכות המורים לא הייתה נמוכה יותר מזו שבין המורים לבין עצמם - ולעיתים אף גבוהה ממנה. רגע הגילוי עורר דיון פורה, והמחיש כיצד מערכת מבוססת בינה מלאכותית יכולה ליישם עקרונות של שיפוט פדגוגי, גם כאשר היא פועלת על בסיס לוגיקה שונה, ולעיתים בלתי נראית.



Alameh, S., Abd-El-Khalick, F., & Brown, D. (2022). The nature of scientific explanation: Examining the perceptions of the nature, quality, and “goodness” of explanation among college students, science teachers, and scientists. **Journal of Research in Science Teaching**, 60(1), 100–135. <https://doi.org/10.1002/tea.21792>

Ariely, M., Nazaretsky, T., & Alexandron, G. (2024). Causal-mechanical explanations in biology: Applying automated assessment for personalized learning in the science classroom. **Journal of Research in Science Teaching**, 61(8), 1858–1889. <https://doi.org/10.1002/tea.21929>

de Andrade, V., Freire, S., & Baptista, M. (2019). Constructing scientific explanations: A system of analysis for students’ explanations. **Research in Science Education**, 49(3), 787–807. <https://doi.org/10.1007/s11165-017-9648-9>

Gerard, L. F., & Linn, M. C. (2016). Using automated scores of student essays to support teacher guidance in classroom inquiry. **Journal of Science Teacher Education**, 27(1), 111–129.

Krist, C., Schwarz, C. V., & Reiser, B. J. (2019). Identifying essential epistemic heuristics for guiding mechanistic reasoning in science learning. **Journal of the Learning Sciences**, 28(2), 160–205. <https://doi.org/10.1080/10508406.2018.1510404>

Nazaretsky, T., Ariely, M., Cukurova, M., & Alexandron, G. (2022). Teachers’ trust in AI-powered educational technology and a professional development program to improve it. **British Journal of Educational Technology**, 53(4), 914–931. <https://doi.org/10.1111/bjet.13232>

Tansomboon, C., Gerard, L. F., Vitale, J. M., & Linn, M. C. (2017). Designing automated guidance to promote productive revision of science explanations. **International Journal of Artificial Intelligence n Education**, 27(4), 729–757.



