מודל קבלת השימוש ביישומי בינה מלאכותית
כגורם מתווך בין משתני אישיות ורקע לבין דפוסי שימוש בבינה מלאכותית יוצרת

Mediation of Artificially Intelligent Device Use Acceptance (AIDUA) in the relationship between personality and background variables with Generative Artificial Intelligence usage

מור דשן
אוניברסיטת בר-אילן
mor.deshen@biu.ac.il

נועה אהרוני
אוניברסיטת בר אילן
noa.aharony@biu.ac.il

תקציר

בינה מלאכותית יוצרת (Generative Artificial Intelligence - GenAI) מייצגת תמורה משמעותית בנוף הטכנולוגי, אך דפוסי האימוץ שלה טרם התבררו עד תום. בעוד שחלק מהמשתמשים מאמצים את הטכנולוגיה המתפתחת, אחרים מפגינים הססנות. מחקר זה בוחן את הקשר בין משתני אישיות ורקע לצד משתני מודל קבלת השימוש ביישומי בינה מלאכותית (Artificial Intelligence Device Use Acceptance - AIDUA) לבין דפוסי השימוש ב־GenAI בקרב מבוגרים בישראל. מטרת המחקר היא להבין כיצד גורמים אלו מעצבים את מידת המעורבות בטכנולוגיה מתהווה זו.

במחקר השתתפו 291 נבדקים בגילי 18 עד 83 אשר ענו על סקר מקוון. השאלון אסף משתני רקע כגון גיל, מגדר והשכלה וכן דפוסי שימוש ביישומי GenAI, דוגמת ChatGPT. המחקר התמקד בשלושה גורמים מרכזיים: (1) קבלת השימוש ביישומי בינה מלאכותית; (2) פתיחות; (3) מסוגלות־עצמית באוריינות־מידע.

הממצאים מראים שמוטיבציה־נהנתנית שימשה כגורם מתווך בהשפעות של פתיחות, גיל, מגדר והשכלה על השימוש ב־GenAI. השפעה־חברתית נמצאה כמתווכת את הקשר הנוגע לפתיחות, בעוד שציפייה למאמץ תיווכה את ההשפעות הקשורות לגיל ולמגדר. בנוסף, נמצאו מתאמים מובהקים בין שימוש ב־GenAI ובין השפעה־חברתית, מוטיבציה־נהנתנית, רגשות־חיוביים, פתיחות, מסוגלות־עצמית באוריינות־מידע, גיל והשכלה. רמת־הביצוע־המצופה לא נמצאה במתאם מובהק עם השימוש. הממצא המרכזי מעלה כי מוטיבציה־נהנתנית היא הגורם בעל הקשר החזק ביותר עם אימוץ הטכנולוגיה.

ממצאי המחקר עשויים להנחות קובעי מדיניות וגורמים בתעשייה במאמציהם לקדם שימוש נרחב יותר ב־GenAI. הבנת השונות בדפוסי השימוש תאפשר לארגונים לגבש תוכניות הדרכה ממוקדות ומותאמות למשתמשים השונים במטרה להסיר חסמים ולהנגיש את הטכנולוגיה החדשנית.

מילות מפתח – בינה מלאכותית יוצרת (GenAI); קבלת שימוש ביישומי בינה מלאכותית; פתיחות; מסוגלות עצמית באוריינות מידע.

Abstract

Purpose: Generative Artificial Intelligence (GenAI) represents a significant shift, yet its usage remains inconsistent. While some embrace GenAI, others remain hesitant. This study examines the personal and background variables, with Artificial Intelligence Device Use Acceptance (AIDUA) variables that may be associated with GenAI usage among Israeli adults, aiming to understand how these factors shape engagement with this emerging technology.

Methodology: A total of 291 participants, aged 18 to 83, completed an online survey using a closed questionnaire. The questionnaire assessed background variables such as age, gender, education, and patterns of usage for generative Artificial Intelligence, focusing on three main factors: (1) Acceptance of Artificially Intelligent Device Use (AIDUA), (2) a personality characteristic - Openness, and (3) Self-Efficacy in Information-Literacy (ILSE).

Findings: Concerning the utilization of GenAI applications, hedonic motivation served as a mediating factor in the effects associated with Openness, age, gender, and education; social influence mediated the relationship concerning Openness; and effort-expectancy acted as a mediating variable in the effects related to age and gender. Furthermore, correlations were found between GenAI chatbot usage and social-influence, hedonic-motivation, positive-emotions, Openness, information-literacy self-efficacy, age, and education. Performance-expectancy did not correlate significantly with usage. Notably, hedonic-motivation emerged as the most influential factor.

Practical implications: The current findings can guide policy and industry efforts to promote broader usage of GenAI chatbots. By gaining insights into how usage patterns vary, organizations are better positioned to implement targeted outreach, training programs, and design adjustments to remove barriers.

Keywords - Generative Artificial Intelligence (GenAI); Artificially Intelligent Device Use Acceptance (AIDUA); Information literacy self-efficacy (ILSE); Openness.

מבוא

הופעתם של יישומי בינה מלאכותית יוצרת (Generative Artificial Intelligence - GenAI), ובפרט יישומים המבוססים על מודלי שפה גדולים (Large Language Models - LLMs), דוגמת ChatGPT, מסמנת תמורה מהותית ביחסי הגומלין שבין אדם למכונה בסביבה הדיגיטלית (Liu, 2024). ייחודם של כלים אלו נעוץ ביכולתם לקיים אינטראקציה בשפה טבעית, להפיק תוכן חדש ולהשתלב בתהליכי כתיבה, למידה, יצירה, פתרון בעיות וקבלת החלטות (Ivcevic & Grandinetti, 2024; Lim et al., 2025). לצד פוטנציאל זה, אימוץ GenAI מלווה באי־ודאות הנובעת לא רק משינויים בציפיות התעסוקתיות, מאוטומציה גוברת ומאיומים נתפסים על תפקידים מסורתיים (Park et al., 2024), אלא גם מסוגיות הנוגעות לאמון בתוצרי המערכת, להטיות, לפרטיות ולהתמודדות עם תוצרים שגויים או "הזיות" הנחזים כאמינים (Farquhar et al., 2024; Huynh & Aichner, 2025). לפיכך, התועלות הפוטנציאליות של GenAI אינן תלויות רק בנגישות לטכנולוגיה, אלא גם ביכולתו של המשתמש לקיים עמה אינטראקציה מושכלת, ביקורתית ומודעת להקשר (Bankins et al., 2023).

בעוד שחלק מן המשתמשים מאמצים יישומי GenAI באופן אקטיבי ומשלבים אותם בדפוסי עבודה, למידה ויצירה, אחרים מפגינים היסוס, חשש או הימנעות, ובכך עלולים להחמיץ הזדמנויות לפיתוח מיומנויות, חדשנות ופרודוקטיביות. מחקרים עדכניים מצביעים על כך שאימוץ GenAI אינו אחיד, אלא מושפע ממאפייני רקע, מהקשרי שימוש, ממיומנויות דיגיטליות, מתפיסת סיכון, מאמון בתוצרי המערכת ומרמת התמיכה ורמת ההכשרה העומדות לרשות המשתמשים (Brynjolfsson et al., 2025; Hernández-Tamurejo et al., 2025). בהקשרים של תעסוקה וחינוך היסוס זה עלול להחריף פערי מיומנויות ולהוביל לאי־רלוונטיות מקצועית, במיוחד בקרב משתמשים שאינם מקבלים הכשרה מספקת או שאינם חשים מסוגלים להשתמש בטכנולוגיה באופן ביקורתי ומועיל (Deranty & Corbin, 2024; Ivcevic & Grandinetti, 2024). בהקשר הישראלי נמצא כי תפיסות הציבור כלפי AI אינן אחידות, וכי לצד תפיסות אוטופיות המדגישות את תרומת הטכנולוגיה קיימות גם תפיסות דיסטופיות הנוגעות לפגיעה בפרטיות, באוטונומיה, ביחסים חברתיים ובשוק העבודה (Sabag-Ben Porat, 2025).

מימוש מיטבי של יתרונות ה־GenAI מחייב הבנה של המאפיינים הפסיכולוגיים, הקוגניטיביים והמידעניים המעצבים את התנהגות המשתמש. השימוש בטכנולוגיה אינו מושפע רק מנגישות או מתועלת נתפסת, אלא גם מאמון, ממוכנות רגשית, מתחושת מסוגלות ומקיומם של רגשות חיוביים כלפי האינטראקציה עם AI (Huynh & Aichner, 2025; Park et al., 2024). מנגד, תחושות של חוסר אונים, חרדה טכנולוגית, חשש מהחלפה על ידי מכונה, אמון נמוך בתוצרי AI או קושי להעריך את אמינות התוצרים עשויות להשפיע על נכונות המשתמשים להתנסות, ללמוד ולהמשיך להשתמש ביישומי GenAI, ואף להוביל להימנעות, לשימוש שטחי או לתלות בלתי מבוקרת בטכנולוגיה (Hernández-Tamurejo et al., 2025; Lim et al., 2025; Yin et al., 2024). בהקשר זה, אוריינות מידע מקבלת חשיבות מיוחדת, שכן משתמשי GenAI נדרשים לא רק להפעיל כלי דיגיטלי, אלא גם לנסח בקשות אפקטיביות, להעריך את אמינות התוצרים, לזהות אי־דיוקים והטיות ולהבחין בין ניסוח משכנע לבין מידע אמין. קידום השימוש ב־GenAI מחייב אם כן הבנה של דפוסים אישיותיים אלו, ובפרט של תרומתה של פתיחות להתנסויות בעיצוב הנכונות להתנסות בטכנולוגיות חדשות, לחקור שימושים יצירתיים ולפתח עמדות חיוביות כלפי GenAI (Alagöz Hamzaj, 2025; Bankins et al., 2023).

לאור זאת, נדרש מחקר אמפירי ממוקד בנוגע לגורמים המעצבים את השימוש ב־GenAI ברמת הפרט. על אף שהספרות העוסקת באימוץ GenAI התרחבה במהירות בשנים האחרונות, חלק ניכר ממנה מתמקד

בכוונות שימוש, בעמדות כלליות או בהקשרים מוסדיים ומקצועיים ספציפיים, כגון השכלה גבוהה, עבודה ובריאות. מחקרים עדכניים אף מצביעים על כך שמודלים קלאסיים של קבלת טכנולוגיה, ובהם UTAUT ו־TAM, מורחבים כיום באמצעות משתנים כגון אמון, סיכון, פרטיות והערכת אמינות התוצרים (Lim et al., 2025; Su et al., 2025; Wang et al., 2025). עם זאת, עדיין נדרשת הבנה טובה יותר של האופן שבו מאפייני אישיות ורקע נקשרים לשימוש בפועל ביישומי GenAI בקרב אוכלוסייה בוגרת כללית, ושל המנגנונים המתווכים קשרים אלה. בהקשר זה, בחינת משתנים כגון פתיחות, מסוגלות־עצמית באוריינות־מידע, ועמדות כלפי קבלת טכנולוגיית AI עשויה לתרום להבנת התנאים הפסיכולוגיים והחווייתיים המעודדים או מעכבים שימוש ב־GenAI.

מחקר זה מתבסס על מסורת המחקר של קבלת טכנולוגיה, אך עושה זאת מתוך הכרה בכך שסביבת GenAI מציבה אתגרים ייחודיים למודלים קלאסיים. מודלים כגון TAM ו־UTAUT סיפקו בסיס מרכזי להבנת אימוץ טכנולוגיות באמצעות משתנים כגון תועלת נתפסת, קלות שימוש, השפעה חברתית וציפיית ביצוע (Davis, 1989; Venkatesh et al., 2003). עם זאת, מודלים אלה אינם מתייחסים באופן ספציפי למאפייניה של GenAI, ובכללם אינטראקציה בשפה טבעית, יצירת תוכן אקטיבית, אמון בתוצרים והצורך בהערכת אמינותם. בהתאם לכך, המחקר הנוכחי עושה שימוש ב־AIDUA כמסגרת תיאורטית המותאמת לקבלת יישומי AI, תוך בחינת הרלוונטיות של ממדיה לשימוש בפועל ביישומי GenAI.

בהמשך לכך, המחקר בוחן את הקשרים שבין שימוש ביישומי GenAI לבין משתני רקע ושלושה צירים מרכזיים: (1) עמדות כלפי קבלת טכנולוגיית AI, המבוססות על מודל ה־AIDUA, ובכללן **השפעה־חברתית, מוטיבציה־נהנתנית, רמת־המאמץ־המצופה, רמת־הביצוע־המצופה ורגשות־חיוביים**; (2) **פתיחות**; ו־(3) **מסוגלות־עצמית באוריינות־מידע**. תרומת המחקר היא בבחינת האופן שבו צירים אלה משתלבים בהסבר שימוש בפועל ב־GenAI בקרב אוכלוסייה בוגרת כללית בישראל, ובזיהוי מנגנונים מתווכים שבאמצעותם מאפייני אישיות ורקע נקשרים לדפוסי שימוש בטכנולוגיה.

סקירת ספרות

מחקר זה בוחן משתנים אשר נמצאו במחקרים קודמים כבעלי מתאם עם דפוסי שימוש בטכנולוגיה. תתי־הסולמות של מודל ה־AIDUA (קבלת שימוש ביישומים בעלי בינה מלאכותית) נמצאו קשורים לכוונות התנהגותיות לשימוש בטכנולוגיות AI (Cao et al., 2021; Strzelecki, 2023).

המאפיין פתיחות, הנגזר ממודל האישיות "חמש התכונות הגדולות" (Big Five, John & Srivastava, 1999), נקשר בעבר לקבלת טכנולוגיות חדשות (Aharony, 2015a; Seibert et al., 2021).

באופן דומה, מסוגלות־עצמית באוריינות־מידע (Kurbanoğlu et. al., 2003; 2006) נמצאה בקורלציה עם דפוסי שימוש בטכנולוגיות מידע (Jang et al., 2021; Nikou et al., 2022).

למרות התרחבות הספרות העדכנית על אימוץ GenAI, עדיין נדרש בירור אמפירי של האופן שבו ממדי AIDUA, פתיחות ומסוגלות־עצמית באוריינות־מידע משתלבים יחד בהסבר שימוש בפועל ביישומי GenAI.

אימוץ טכנולוגיות בינה מלאכותית נשען על מסורת מחקרית קודמת של מודלים לקבלת טכנולוגיה, ובהם מודל קבלת הטכנולוגיה (Technology Acceptance Model - TAM), שפותח על ידי דייויס (Davis, 1989), והתיאוריה המאוחדת לקבלה ולשימוש בטכנולוגיה (Unified Theory of Acceptance and Use of Technology - UTAUT; Venkatesh et al., 2003). בגרסתו השנייה UTAUT2 (Venkatesh et al., 2012), הורחב המודל באמצעות הוספת משתנים נוספים. בהתבסס עליהם ובהתייחס לסביבת הבינה המלאכותית

פותחה מסגרת מושגית העוסקת בקבלת השימוש ביישומי בינה מלאכותית (AIDUA; Gursoy et al., 2019), המשלבת מבנים תיאורטיים נוספים ומזקקת את כלי המדידה עבור תחום הבינה המלאכותית, במטרה להבין את הגורמים המשפיעים על קבלת המשתמשים ועל האינטראקציה שלהם עם יישומי AI. **טבלה 1** מציגה את משתני AIDUA שנבחנו במחקר ואת זיקתם למודלים קודמים של קבלת טכנולוגיה.

טבלה 1. משתני קבלת השימוש במכשירים מבוססי AI (AIDUA; Gursoy et al., 2019)

	שם המדד		הגדרה	TAM (Davis, 1989)	UTAUT (Venkatesh et al., 2003)
1	השפעה־חברתית	Social influence	התפיסה כי משפחה, עמיתים או הקהילה מצפים ומעודדים את הפרט להשתמש ב־AI	✗	✓
2	מוטיבציה־נהנתנית	motivation־Hedonic	תחושת ההנאה והעונג הנחווים בעת אינטראקציה עם כלי AI	✗	✗
3	רמת־הביצוע־המצופה	Performance-expectancy	האמונה כי AI תשפר יעילות, אפקטיביות או תוצאות יום־יומיות	✓[1]	✓
4	רמת־המאמץ־המצופה	Effort-expectancy	המידה שבה השימוש ב־AI נתפס כקל ודורש מעט מאמץ	✓[2]	✓
5	רגשות־חיוביים	Positive-emotions	תגובות רגשיות חיוביות כגון אמון, נוחות או התלהבות, המעודדות מעורבות עם AI	✗ / ✓[3]	✗

[1] נקרא במקור perceived usefulness.
[2] נקרא במקור perceived ease of use.
[3] רגש משתקף באופן חלקי בלבד ב־TAM (כעמדה כלפי שימוש) ובהרחבות UTAUT2 (כהנאה או אמון), אך אינו נכלל כמבנה ליבה.

מודל AIDUA מהווה מסגרת תיאורטית מתקדמת ורלוונטית לחקר קבלת השימוש ביישומי בינה מלאכותית, שכן הוא פותח במיוחד עבור הקשרים שבהם המשתמשים מקיימים אינטראקציה עם מערכות מבוססות AI, ולא רק עם טכנולוגיות מידע כלליות. יתרונו של המודל בכך שהוא משמר רציפות תיאורטית עם מסורת קבלת הטכנולוגיה. עם זאת, התפתחותם המהירה של יישומי GenAI, המתאפיינים באינטראקציה בשפה טבעית, ביצירת תוכן אקטיבית ובצורך בהערכת אמינות התוצרים, מחייבת בחינה אמפירית של האופן שבו ממדי AIDUA פועלים בהקשר טכנולוגי חדש זה באופן כללי ובהקשר הישראלי בפרט. בהתאם לכך, במחקר הנוכחי נכללו במודל ובשאלון המחקר המשתנים האלה: השפעה־חברתית, מוטיבציה־נהנתנית, רמת־המאמץ־המצופה, רמת־הביצוע־המצופה ורגשות־חיוביים.

השפעה־חברתית (Social-Influence)

השפעה־חברתית מתייחסת למידה שבה אנשים המשמעותיים לפרט משפיעים על החלטותיו בנוגע לשימוש בטכנולוגיה (Venkatesh et al., 2003). בספרות המחקר נמצא שהשפעה־חברתית קשורה באופן בולט לכוונות התנהגותיות לאימוץ טכנולוגיות (Maruping et al., 2017; Venkatesh et al., 2012; Yu et al., 2021). בהקשר של טכנולוגיות AI, משתנה זה ממלא תפקיד מרכזי, במיוחד כאשר אינטראקציות בין־אישיות מעצבות את עמדות המשתמשים ואת רמת־הביצוע־המצופה מהטכנולוגיה. כמו כן השפעה־חברתית נקשרה באופן חיובי לקבלת יישומי AI וכלי GenAI (Gursoy et al., 2019; Kelly et al., 2023). סביבות חברתיות חיוביות מעודדות עמדות אוהדות כלפי יישומי מבוססי GenAI (Strzelecki, 2023). מחקרים עדכניים בקרב סטודנטים לתואר ראשון ולתארים מתקדמים (Korchak *et al.*, 2025), בקרב מורים ישראלים (Deshen *et al.*, 2026), ובקרב סטודנטים להשכלה גבוהה בישראל (Deshen & Aharony, 2026) מצביעים אף הם על זיקה בין השפעה־חברתית לבין אימוץ טכנולוגיות GenAI.

לאור ממצאים אלו אנו מניחים כי:

השערה 1: יימצא קשר חיובי בין השפעה־חברתית לבין השימוש ביישומי מבוססי GenAI

מוטיבציה־נהנתנית (Hedonic-Motivation)

מוטיבציה־נהנתנית נוגעת להנאה המופקת מעצם האינטראקציה עם הטכנולוגיה (Gursoy et al., 2019). משתמשים המונעים משיקולים נהנתניים נוטים להחזיק בעמדות חיוביות כלפי השימוש בטכנולוגיה (Baabdullah, 2018; Strzelecki, 2023). יתר על כן, הרצון בחוויה מהנה זוהה כגורם קריטי באימוץ ושימוש בטכנולוגיה (Deng & Yu, 2023; Oluwajana et al., 2019; Venkatesh et al., 2012). מחקרים אחרים מצאו שמוטיבציה־נהנתנית קשורה עם שימוש ביישומי AI (Strzelecki, 2023). מחקרים עדכניים מחזקים את הרלוונטיות של מוטיבציה־נהנתנית בהקשר של שימוש ב־GenAI: בקרב משתמשי ChatGPT בהשכלה גבוהה היא נמצאה כתורמת לכוונות אימוץ ולשימוש בפועל (Subhani et al., 2025); בקרב סטודנטים להשכלה גבוהה בישראל נמצא קשר חיובי בינה ובין שימוש (Deshen & Aharony, 2026); ובקרב מורים בישראל היא נמצאה כאחד המנבאים המרכזיים של שימוש מקצועי (Deshen et al., 2026).

לפיכך, השערת המחקר היא:

השערה 2: יימצא קשר חיובי בין מוטיבציה־נהנתנית לבין השימוש ביישומי GenAI

רמת־המאמץ־המצופה (Effort-Expectancy)

רמת־המאמץ־המצופה, הידועה גם כ"קלות שימוש נתפסת" (Marangunić & Granić, 2015), מתייחסת לציפיית האדם בנוגע למידת המאמץ שיהיה כרוך בשימוש בטכנולוגיה מסוימת (Chatterjee & Bhattacharjee, 2020; Venkatesh & Davis, 2000). מחקרים שונים הצביעו על תפקידו המכריע של משתנה זה בעיכוב אימוץ טכנולוגיות כגון למידה ניידת (Hu et al., 2020) ומערכות ניהול למידה (Raza et al., 2022). בסביבת ה־AI רמת־המאמץ־המצופה זוהתה בעקביות כגורם משמעותי הקשור לשימוש בפועל (Cao, 2021). סקירה שיטתית איששה כי משתנה זה קשור במידה רבה לכוונות התנהגותיות ולשימוש בפועל ב־AI במגוון רחב של תעשיות (Kelly et al., 2023).

מחקרים עדכניים בהקשר של GenAI מחזקים את הרלוונטיות של רמת־המאמץ־המצופה: בקרב מורים ישראלים היא נמצאה כמנבא מובהק של שימוש מקצועי ב־GenAI (Deshen et al., 2026), במחקר חוצה־מדינות בהשכלה גבוהה היא נמצאה כגורם מובהק בכוונות אימוץ (Menon et al., 2024), ובקרב סטודנטים היא נמצאה כאחד הגורמים שניבאו כוונת המשך שימוש (Holzmann et al., 2025).

לפיכך הנחנו כי:

השערה 3: יימצא קשר שלילי בין רמת־המאמץ־המצופה לבין השימוש ביישומי GenAI

רמת־הביצוע־המצופה (Performance-Expectancy)

רמת־הביצוע־המצופה, המוכרת גם כ"תועלת נתפסת" (Marangunić & Granić, 2015), מתייחסת לאמונה ביתרונות ובאפקטיביות של הטכנולוגיה. משתנה זה משפיע על דפוסי השימוש באמצעות תפיסת המשתמש בנוגע ליכולתה של הטכנולוגיה לענות על צרכיו (Gursoy et al., 2019; Venkatesh & Davis, 2000). באופן ספציפי, המשתנה נבחן כמידת הציפייה של הפרט כי הטכנולוגיה תשפר את ביצועיו בעבודה, וגורם זה הוא ציר מרכזי בעיצוב כוונות התנהגותיות ועמדות כלפי הטכנולוגיה (Cao et al., 2021; Chen et al., 2011). בסביבות אקדמיות, רמת־הביצוע־המצופה נמצאה קשורה עם כוונות המשתמשים לאמץ כלים כגון Google Scholar, ספרים אלקטרוניים, טכנולוגיות Web 2.0 ופלטפורמות בגישה פתוחה (Aharony, 2015a, 2015b; Aharony & Prebor, 2015). כמו כן, משתנה זה זוהה כגורם מפתח בכוונות אימוץ AI במגזרים שונים (Cao et al., 2021; Strzelecki, 2023). מחקרים עדכניים בהקשר של GenAI מחזקים אף הם את חשיבותה של רמת־הביצוע־המצופה: בקרב סטודנטים המשתמשים ב־ChatGPT היא נמצאה כמנבא החזק

ביותר של כוונת המשך שימוש (Holzmann et al., 2025); במחקר חוצה־מדינות בהשכלה גבוהה היא נמצאה כגורם מובהק בכוונות אימוץ (Menon et al., 2024); בקרב סטודנטים בפקיסטן היא נמצאה כגורם מובהק בכוונות אימוץ, שבתורן ניבאו שימוש בפועל (Subhani et al., 2025); ובקרב מורים נמצא קשר מובהק בינה לבין שימוש מקצועי (Deshen et al., 2026).

לאור הממצאים האלה, השערת המחקר היא:

השערה 4: יימצא קשר חיובי בין רמת־הביצוע־המצופה לבין השימוש ביישומי GenAI

רגשות־חיוביים (Positive-emotions)

רגשות־חיוביים ממלאים תפקיד חיוני בשימוש בטכנולוגיות חדשות. רגשות כגון התרגשות ושמחה מקדמים עמדות חיוביות, בעוד שרגשות שליליים כגון פחד וחרדה יוצרים התנגדות (Beaudry & Pinsonneault, 2010). מחקרים הראו כי רגשות־חיוביים קשורים לנכונותם של לקוחות לקבל שימוש באמצעות יישומי AI כאשר הם מקבלים שירות (Gursoy et al., 2019). מחקרים עדכניים מחזקים את הרלוונטיות של ממד רגשי זה בהקשר של GenAI: רגשות נמצאו כתורמים לאמון במערכות GenAI ולעמדות כלפיהן (Huynh & Aichner, 2025); בקרב סטודנטים להשכלה גבוהה נמצא קשר חיובי בין רגשות כלפי AI לבין שימוש (Deshen & Aharony, 2026); ובקרב מורים ישראלים נמצא קשר מובהק בין רגשות חיוביים כלפי AI לבין שימוש מקצועי ב־GenAI (Deshen et al., 2026).

על בסיס זה מוצעת ההשערה:

השערה 5: יימצא קשר חיובי בין רגשות־חיוביים לבין השימוש ביישומים מבוססי GenAI

פתיחות (Openness)

תכונת הפתיחות נגזרת ממודל "חמש התכונות הגדולות" (McCrae & Costa, 1992). מאפיין זה מתבטא בעניין רב בעולם, בנכונות לחקור דברים חדשים ובהרחבת אופקים (McCrae & Costa, 1988). מחקרים קודמים מצאו מתאמים בין פתיחות לבין קבלת טכנולוגיה, דפוסי חיפוש מידע (Halder et al., 2010) ועמדות חיוביות כלפי טכנולוגיות מידע (Aharony & Shonfeld, 2015). פתיחות נמצאה כקשורה משמעותית לכוונות שימוש במחשוב ענן (Aharony, 2015a) ולאימוץ טכנולוגיות חדשות (Seibert et al., 2021). מחקרים עדכניים בהקשר של GenAI מחזקים את הרלוונטיות של פתיחות: בקרב פרחי הוראה נמצא כי תכונות הכלולות ב"חמש התכונות הגדולות", ובכללן פתיחות להתנסויות, קשורות לקבלת GenAI ולעמדות כלפיו (Alagöz Hamzaj, 2025); בקרב סטודנטים בהשכלה גבוהה נמצא כי פתיחות להתנסויות קשורה באופן חיובי לשימוש חינוכי ב־GenAI, ואף הייתה המנבא החזק ביותר של שימוש זה (Arpaci et al., 2025); ובקרב סטודנטים להשכלה גבוהה בישראל נמצא קשר חיובי בין פתיחות לבין שימוש (Deshen & Aharony, 2026).

לפיכך הנחנו כי:

השערה 6: יימצא קשר חיובי בין פתיחות לבין השימוש ביישומי GenAI

מסוגלות־עצמית באוריינות־מידע (ILSE)

מסוגלות־עצמית באוריינות־מידע היא משתנה קריטי במחקר זה, שכן היא משקפת את יכולתו הנתפסת של הפרט לאתר, להעריך וליישם מידע, ואלו מיומנויות החיוניות לשימוש מושכל ביישומים מבוססי GenAI. אוריינות מידע מוגדרת כמכלול של כשירויות המאפשרות לפרט מעורבות פעילה בפתרון בעיות (American Library Association, 1989). היעדר מיומנויות אלו עלול להגביר את התפשטות המידע הכוזב ולהרחיב את

פערי הידע (Spisak, 2023). על פי תיאוריית המסוגלות העצמית של בנדורה (Bandura, 1993), אמונות אלו קובעות כיצד אנשים חושבים, מתנהגים ומניעים את עצמם. במחקרים קודמים נמצא כי רמות גבוהות יותר של פתיחות, בשילוב עם שימוש תדיר, מעלות את רמת המסוגלות העצמית של סטודנטים באוריינות מידע (Aharony & Gazit, 2019). יחד עם זאת, בהקשר של GenAI, הקשר בין מסוגלות־עצמית באוריינות־מידע לבין שימוש בפועל עדיין נחקר במידה מוגבלת, במיוחד בקרב אוכלוסייה בוגרת כללית.

על כן, גובשה ההשערה:

השערה 7: יימצא קשר חיובי בין מסוגלות־עצמית באוריינות־מידע לבין השימוש ביישומי GenAI

הגדרת הבעיה

בשנים האחרונות ספרות מחקר ענפה בחנה את הקשר שבין קבלת טכנולוגיה לבין דפוסי השימוש בה, תוך התבססות על מודלים קלאסיים כגון UTAUT ו־UTAUT2 (Venkatesh et al., 2003; 2012). מחקרים אלו שילבו לעיתים קרובות גם מאפייני אישיות, דוגמת מדד הפתיחות ומדד מסוגלות־עצמית באוריינות־מידע. שילובים אלו אפשרו להעמיק את ההבנה בנוגע לזיקה שבין מאפייני המשתמש לבין אימוץ טכנולוגיות מידע מגוונות.

אף שהספרות העדכנית על אימוץ GenAI התרחבה במהירות, עדיין נדרש מחקר הבוחן שימוש בפועל בקרב אוכלוסייה בוגרת כללית, ובפרט בהקשר הישראלי, שבו עשויים להשתלב פערי גיל, השכלה, אוריינות מידע ותפיסות חברתיות כלפי AI. מחקרים עדכניים שנערכו בישראל מצביעים על כך שקבלת טכנולוגיות AI קשורה למאפייני רקע של המשתמשים. כך למשל, בקרב מדגם ישראלי נמצא כי גיל, הכנסה והשכלה קשורים הן לחשש מהחלפה על ידי AI והן לנכונות לאמץ טכנולוגיות AI בחיים האישיים והמקצועיים (Vasiliu & Yavetz, 2026). עם זאת, מחקרים אלו עסקו בקבלת AI באופן כללי, בעוד שהמחקר הנוכחי מתמקד בשימוש בפועל ביישומי GenAI ובמנגנוני התיווך הפסיכולוגיים הקשורים אליו.

מחקר זה נועד לגשר על הפער האמור באמצעות בחינת הקשר בין משתני קבלת טכנולוגיה לבין השימוש ביישומי GenAI. המשתנים שנבדקו לקוחים ממדד AIDUA (Gursoy et al., 2019) וכוללים: השפעה־חברתית; מוטיבציה־נהנתנית; רמת־הביצוע־המצופה; רמת־המאמץ־המצופה; ורגשות־חיוביים. נוסף על אלו, המחקר בוחן את הזיקה שבין פתיחות ומסוגלות־עצמית באוריינות־מידע לבין דפוסי השימוש ב־GenAI. מעבר לבחינת הקשרים הישירים בין משתנים אלה לבין שימוש ב־GenAI, המחקר הנוכחי בוחן גם את תפקידם של ממדי AIDUA כמנגנונים מתווכים, שבאמצעותם מאפייני רקע ופתיחות עשויים להיקשר לדפוסי שימוש בפועל. לאור אופיה הייחודי והחדשני של הבינה המלאכותית היוצרת, בחינה זו עשויה לחשוף קשרים חדשים או בלתי צפויים הייחודיים לטכנולוגיה זו, ובכך לתרום להבנה התיאורטית והיישומית של אימוץ AI בעידן הנוכחי.

מתודולוגיה

הליך המחקר

איסוף הנתונים התבצע בתחילת שנת 2024 באמצעות סקר מקוון שהופץ בקרב משיבים הרשומים ב־iPanel, פאנל אינטרנטי ישראלי המשמש לאיסוף נתונים עבור מחקרי שוק, סקרי דעת קהל ומחקרים אקדמיים. חברי הפאנל מקבלים הזמנות להשתתפות בסקרים בהתאם למאפייניהם הדמוגרפיים, והשתתפותם עשויה להיות מתוגמלת באמצעות מנגנון נקודות או שוברים, כמקובל בפאנלים מקוונים מסוג זה. השימוש בפאנל אפשר גישה מהירה למדגם מגוון של מבוגרים בישראל בעלי נגישות לאינטרנט, אך הוא גם מחייב התייחסות להטיות אפשריות הנובעות מהשתתפות מתוגמלת ומבחירה עצמית של משיבים. כדי לצמצם פגיעה אפשרית

באיכות הנתונים, נבדקו הנתונים לאיתור דפוסי מענה חריגים, ערכי קיצון וחוסר עקביות. כמו כן, השאלון היה אנונימי, ולא נאסף מידע מזהה אישי, במטרה להפחית לחצי רצייה חברתית ולעודד מענה כן.

המשתתפים

המדגם כלל 291 מבוגרים מישראל, בגילי 18 עד 83 ($M = 40.49$, $SD = 15.11$). כמחצית מהמשתתפים היו גברים ($n = 146$, 50.2%). רוב המשיבים היו בעלי השכלה אקדמית ($n = 189$, 64.9%), והיתר ללא השכלה אקדמית ($n = 102$, 35.1%). באשר לשימוש ביישומי GenAI, רוב משתתפי המדגם דיווחו כי הם משתמשים בטכנולוגיה זו ($n = 178$, 61.2%).

כלי המחקר

המחקר התבסס על שיטה כמותית וכלל שאלון סגור. השאלון הורכב מארבעה חלקים (נספח 1):

1. משתני רקע ודפוסי שימוש: חלק זה כלל שאלות דמוגרפיות (מגדר והשכלה) ושאלות הנוגעות למאפייני השימוש ב־GenAI, ובכללן: האם הנבדק משתמש בבינה מלאכותית ובאילו פלטפורמות, מטרות ומוצרים הוא נעזר.
2. מודל ה־AIDUA (Gursoy et al., 2019). הפריטים נמדדו על גבי סולם ליקרט בן 5 דרגות, הנע בין 1 (מסכים מאוד) ל־5 (לא מסכים כלל). יוצא דופן היה הפרק שהעריך רגשות, אשר נמדד באמצעות סולם דו־קוטבי (Bipolar scale) בן 5 דרגות (למשל: 1 – משועמם; 5 – רגוע).

פריטי השאלון תורגמו והותאמו להקשר של שימוש ביישומי GenAI בקרב דוברי עברית בישראל. אף שמדובר בכלי המבוסס על שאלון קיים ומתוקף, התאמתו להקשר טכנולוגי, לשוני ותרבותי שונה הצדיקה בחינה אמפירית של מבנה הפריטים במדגם הנוכחי.

כדי לתקף את מבנה השאלון (32 פריטים), נערך ניתוח גורמים מגשש (EFA) בשיטת מיצוי רכיבים עיקריים (Principal Component Analysis) עם סיבוב וריקס (Varimax). על סמך קריטריון Eigenvalues לערכים עצמיים הגדולים מ־1 (Kaiser, 1960), עלו שישה גורמים. עם זאת, תשעה פריטים הוסרו בשל טעינות על גורמים לא רלוונטיים. ניתוח חוזר הניב פתרון של חמישה גורמים המסבירים כ־71.1% מהשונות: (1) השפעה־חברתית; (2) מוטיבציה־נהנתנית; (3) רמת־מאמץ־מצופה; (4) רמת־ביצוע־מצופה; (5) רגשות־חיוביים כלפי AI. טעינות הפריטים (Factor Loadings) נעו בין 0.71 ל־0.86 על הגורם הרלוונטי. נתוני המהימנות מוצגים בנספח 2.

3. פתיחות: השאלון (על פי John & Srivastava, 1999) כלל עשרה פריטים מתוקפים על סולם ליקרט בן 5 דרגות, הנע בין 1 – במידה מועטה מאוד ל-5 במידה רבה מאוד. במחקר הנוכחי, אלפא של קרונבך עמד על 0.83.
4. מסוגלות־עצמית באוריינות־מידע: השאלון (על פי Kurbanoğlu et al., 2006) כלל 26 היגדים המדורגים על סולם ליקרט בן 7 דרגות, הנע בין 1 (מסכים מאוד) ל־7 (לא מסכים כלל). במחקר הנוכחי, אלפא של קרונבך עמד על 0.96.

ניתוחים סטטיסטיים

טרם ביצוע ניתוחי המודל, נבחנו משתני המחקר לאיתור ערכי קיצון ובדיקת התפלגות נורמלית. הקשרים בין משתני הרקע למשתני המחקר נבחנו באמצעות מבחני χ^2 לאי־תלות, מתאמי פירסון ומתאמים פוינט־ביסריאליים. הערכת טיב התאמת המודל התבצעה על פי מספר מדדים המקובלים בספרות (Hu & Bentler,

1999): מדד χ^2/df – ערך הנמוך מ־5 נחשב לקביל וערך שבין 1 ל־3 נחשב להתאמה מצוינת; CFI (Comparative Fit Index): ערכים מעל ל־0.90 נחשבים לתקינים, וערכים מעל ל־0.95 מעידים על התאמה מצוינת. RMSEA (Root Mean Square Error of Approximation): ערך הנמוך מ־0.08 נחשב לתקין, וערך הנמוך מ־0.06 מעיד על התאמה מצוינת; SRMR (Standardized Root Mean Squared Residual) – ערך הנמוך מ־0.10 נחשב לתקין, וערך הנמוך מ־0.08 מעיד על התאמה מצוינת. נתיבים שנמצאו כלא מובהקים הושמטו מהמודל על מנת להגיע למודל החסכוני ביותר (Bentler & Mooijaart, 1989). לצורך בחינת האפקטים העקיפים (Indirect effects) נאמדו רווחי סמך המבוססים על 5,000 דגימות Bootstrap (Hayes, 2022). האפקטים העקיפים נחשבו למובהקים סטטיסטית כאשר רווח הסמך לא כלל את הערך אפס (Shrout & Bolger, 2002).

הנתונים נותחו באמצעות תוכנת IBM SPSS Statistics (גרסה 29) לצורך סטטיסטיקה תיאורית וניתוחי מתאמים. ניתוח נתיבים בוצע באמצעות תוכנת IBM SPSS Amos (גרסה 24), תוך שימוש בפקודת ה־Specific Indirect Effects (Gaskin et al., 2020), לצורך בחינת השפעות התיווך הספציפיות. רמת המובהקות לכל המבחנים הסטטיסטיים נקבעה על 5% (דו־זנבי).

ממצאים

סטטיסטיקה תיאורית ומתאמים

טרם ביצוע הניתוחים המרכזיים, נבחנו נתוני המחקר לאיתור ערכי קיצון ובדיקת הנחות ההתפלגות. לא נמצאו ערכי קיצון (Z scores < |4|; Hair et al., 2014), וכלל המשתנים נמצאו בטווח ההתפלגות הנורמלית (absolute skewness values < 3 and absolute kurtosis values < 10; Kline, 2016). **טבלה 2** מציגה את הסטטיסטיקה התיאורית ואת המתאמים בין משתני הרקע לבין משתני המחקר.

טבלה 2. ממוצעים, סטיות תקן ואסוציאציות לרקע ולמשתני מחקר

	המשתנה	*M* / %	*SD*	1	2	3	4	5	6	7	8	9	10
1.	גיל	40.49	15.11	-									
2.	מגדר[1]	50.2%	-	.05	-								
3.	השכלה אקדמית[2]	64.9%	-	.01	-.23***	-							
4.	השפעה־חברתית	2.87	0.92	.04	.03	.06	-						
5.	מוטיבציה־נהנתנית	3.60	0.86	-.19**	-.11	.19***	.38***	-					
6.	רמת־המאמץ־המצופה	2.71	0.96	.16**	.18**	-.05	.55***	.08	-				
7.	רמת־הביצוע־המצופה	3.07	0.94	-.07	.10	-.07	.61***	.46***	.47***	-			
8.	רגשות־חיוביים	3.12	0.94	-.13*	-.08	.03	.25***	.38***	-.01	.21***	-		
9.	פתיחות	3.82	0.56	-.14*	.001	.02	.19**	.36***	.08	.15*	.33***	-	
10.	מסוגלות־עצמית באוריינות־מידע	5.53	0.92	-.06	-.04	.09	.12*	.20***	.03	.09	.23***	.51***	-
11.	שימוש ביישומי GenAI	61.2%	-	-.33***	-.02	.27***	.13*	.45***	-.17**	.07	.24***	.15*	.15**

הערה: N = 291 . עבור משתנים רציפים מוצגים מקדמי פירסון. עבור מתאמים בין משתנים דיכוטומיים למשתנים רציפים מוצגים מקדמי מתאם פוינט־ביסריאליים. עבור קשרים בין משתנים דיכוטומיים מוצגים מקדמי מבחני χ2 לאי־תלות. האחוזים המוצגים עבור המשתנים הדיכוטומיים מייצגים את שכיחות הערך העליון בקטגוריה. קידוד מגדר: 0 = אישה, 1 = גבר. קידוד השכלה אקדמית: 0 = לא, 1 = כן.

*$p < .05$. **$p < .01$. ***$p < .001$.

השימוש ביישומי GenAI נמצא קשור באופן מובהק למספר משתנים. מרבית המשתנים ממודל קבלת הטכנולוגיה הראו מתאמים חיוביים עם השימוש, כאשר מוטיבציה־נהנתנית הניבה את הזיקה המובהקת הגבוהה ביותר. ממצא זה מעיד כי משתמשים התופסים את השימוש ב־GenAI כחוויה מהנה, נטו יותר להשתמש בטכנולוגיה בפועל. בניגוד לכך, רמת־ביצוע־מצופה לא נמצאה קשורה באופן מובהק לשימוש. כמצופה, משתנה רמת־מאמץ־מצופה הראה קשר שלילי עם דפוסי השימוש, ממצא המצביע על כך שמשתמשים שתפסו את ה־GenAI כטכנולוגיה הדורשת פחות מאמץ (כלומר, קלה יותר לתפעול), נטו יותר לעשות בה שימוש. נוסף על כך, נמצא מתאם חיובי בין השימוש לבין פתיחות ומסוגלות־עצמית באוריינות־מידע. ממצאים אלו משקפים את החשיבות של מאפייני אישיות ותפיסה עצמית של כשירויות דיגיטליות בעיצוב דפוסי השימוש ב־GenAI.

תכונת הפתיחות הראתה מתאמים מובהקים עם מגוון גורמים של קבלת טכנולוגיה, ובכללם השפעה־חברתית, מוטיבציה־נהנתנית, רמת־ביצוע־מצופה ורגשות־חיוביים ; בולטות במיוחד היו ההשפעות החזקות שנמצאו עבור מוטיבציה־נהנתנית ורגשות־חיוביים.

לבסוף, נמצא קשר חיובי חזק ומובהק סטטיסטית בין מסוגלות־עצמית באוריינות־מידע לבין פתיחות, קשר שמעיד על זיקה מהותית בין שני משתנים אלו במדגם הנוכחי.

השוואה בין משתמשים ושאינם משתמשים ביישומי GenAI הצביעה על כך שמשתמשים מדווחים על רמות גבוהות יותר של השפעה־חברתית, מוטיבציה־נהנתנית, רגשות־חיוביים, פתיחות ומסוגלות־עצמית באוריינות־מידע בהשוואה ללא־משתמשים. מנגד, בקרב משתמשי GenAI רמת־המאמץ־המצופה נמוכה יותר, בעוד שרמת־הביצוע־המצופה מעט גבוהה יותר לעומת מי שאינם משתמשים. נתוני ההשוואה נמצאים בטבלה א בנספח 3.

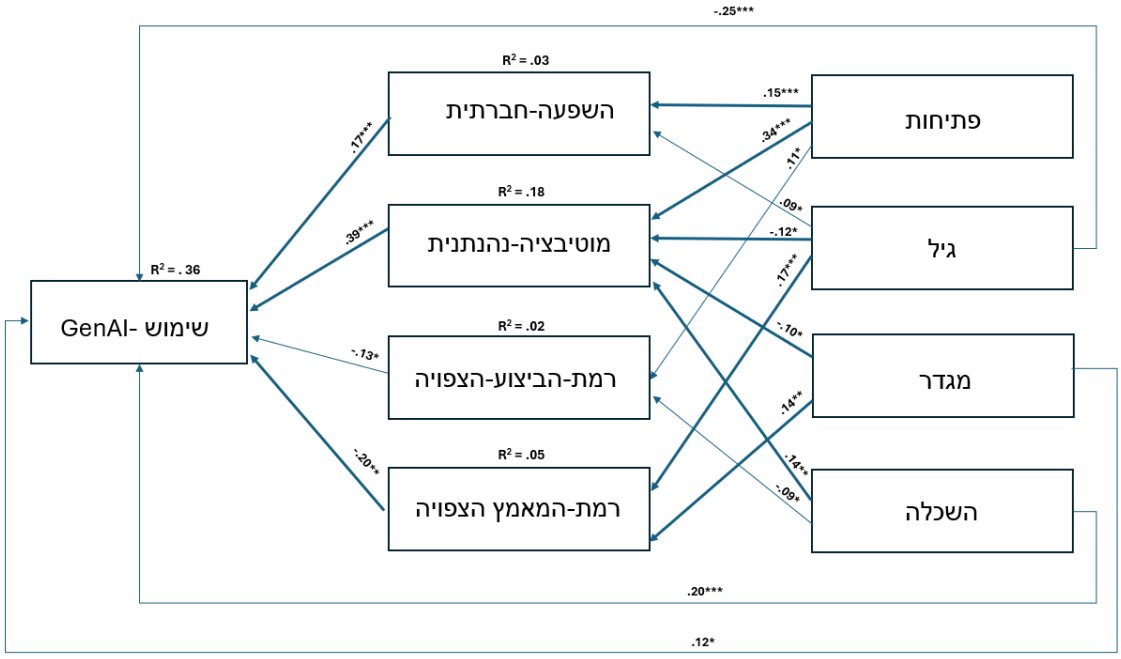
בחינת משתני הרקע העלתה כי לגיל המשיבים זיקה מובהקת למשתני המחקר. נמצא כי גיל המשתתפים עמד במתאם חיובי עם רמת־המאמץ־המצופה ובמתאם שלילי עם מוטיבציה־נהנתנית, רגשות־חיוביים ופתיחות, ואף עם שימוש ביישומי GenAI. במילים אחרות, גיל מבוגר יותר נמצא קשור לתפיסה של יותר מאמץ בעת שימוש בטכנולוגיה, לציונים נמוכים יותר במדדי מוטיבציה־נהנתנית ורגשות־חיוביים, לרמה נמוכה יותר של פתיחות ולסבירות נמוכה יותר לשימוש בפועל ביישומי GenAI. ממצא זה בא לידי ביטוי בהבדלים הממוצעים בין הקבוצות – גילם הממוצע של המשתמשים היה נמוך משמעותית מגילם של אלו שאינם משתמשים. באשר למשתנה המגדר, נמצא קשר לרמת־המאמץ־המצופה, כאשר גברים דיווחו על ציונים גבוהים יותר מנשים במדד זה. לבסוף, נמצא כי לרמת ההשכלה זיקה למוטיבציה־נהנתנית ולשימוש ב־GenAI : משתתפים בעלי השכלה אקדמית הפגינו רמות גבוהות יותר של מוטיבציה־נהנתנית והסתברות גבוהה יותר לשימוש ב־GenAI בהשוואה למשתתפים בעלי השכלה לא־אקדמית. נתוני הממוצעים וסטיות התקן של משתני המחקר בחלוקה למגדר ולהשכלה מפורטים בטבלה ב בנספח 3.

ניתוח נתיבים

ניתוחי המתאמים סיפקו הבנה ראשונית של הקשרים בין משתני המחקר לבין השימוש ביישומי GenAI. עם זאת, לאור חדשנותה של תופעת הבינה המלאכותית היוצרת, שאפנו לחשוף מנגנוני תיווך פוטנציאליים העשויים להסביר כיצד מאפיינים אישיותיים מעצבים את התנהגות השימוש באמצעות מבנים תיאורטיים מבוססים. לשם כך נעשה שימוש בניתוח נתיבים המאפשר להעמיק מעבר למתאמים ולבחון מסלולי הסבר המעוגנים בתיאוריות מוכרות של קבלת טכנולוגיה. גישה זו אפשרה זיהוי של אפקטים עקיפים. מודל הנתיבים המוצג להלן כולל את מרבית משתני המחקר, למעט שני משתנים – מסוגלות־עצמית באוריינות־

מידע ורגשות־חיוביים, אשר הוצאו מהמודל הסופי בשל היעדר מובהקות סטטיסטית של השפעתם בתוך המערך הכולל.

איור 1. מודל ניתוח משוואות מבניות (SEM): ההשפעות העקיפות של פתיחות להתנסות על השימוש ביישומים מבוססי GenAI באמצעות מדדי AIDUA



הערה: N = 291 . האיור מציג מקדמי נתיב מתוקננים (Standardized path coefficients). אפקטים עקיפים מובהקים מיוצגים באמצעות נתיבים המסומנים בקווים מודגשים. טעויות מדידה ומתאמים פנימיים בין המשתנים המתווכים (ראו נספח 4) הושמטו מן התצוגה לצורך בהירות האיור. קידוד מגדר: 0 = אישה, 1 = גבר ; קידוד השכלה אקדמית: 0 = לא, 1 = כן.

$^{*}p < .05$. $^{**}p < .01$. $^{***}p < .001$.

טבלה 3. *תוצאות Bootstrap להשפעות העקיפות של פתיחות להתנסויות, גיל, מגדר והשכלה על השימוש ביישומי GenAI*

השפעה עקיפה	B	95% CI תחתון	95% CI עליון
פתיחות ← השפעה־חברתית ← שימוש ביישומי GenAI	0.020	0.004	0.050
פתיחות ← מוטיבציה־נהנתנית ← שימוש ביישומי GenAI	0.110	0.060	0.170
פתיחות ← רמת־הביצוע־המצופה ← שימוש ביישומי GenAI	-0.010	-0.040	0.001
גיל ← מוטיבציה־נהנתנית ← שימוש ביישומי GenAI	-0.001	-0.003	0.001
גיל ← רמת־המאמץ־המצופה ← שימוש ביישומי GenAI	-0.001	-0.002	0.001
מגדר ← מוטיבציה־נהנתנית ← שימוש ביישומי GenAI	-0.040	-0.080	-0.002
מגדר ← רמת־המאמץ־המצופה ← שימוש ביישומי GenAI	-0.030	-0.060	-0.010
השכלה אקדמית ← מוטיבציה־נהנתנית ← שימוש ביישומי GenAI	0.060	0.010	0.100

הערה: N = 291 .

מוצגים אפקטים עקיפים שנאמדו באמצעות 5,000 דגימות Bootstrap. אפקט עקיף נחשב מובהק כאשר רווח הסמך של 95% אינו כולל את הערך 0.

קידוד מגדר: 0 = אישה, 1 = גבר ; קידוד השכלה אקדמית: 0 = לא, 1 = כן.

$^{*}p < .05$. $^{**}p < .01$. $^{***}p < .001$.

איור 1 מציג את ניתוח הנתיבים המשלב את הקשרים בין המשתנים הבלתי תלויים, המשתנים המתווכים והמשתנה התלוי. הניתוח הראשוני כלל גם את הקשרים של מסוגלות־עצמית באוריינות־מידע ופתיחות עם השימוש ביישומי GenAI. גיל, מגדר והשכלה שימשו כמשתני בקרה. כפי שצוין, נתיבים לא מובהקים הושמטו מן המודל על מנת להגיע למבנה החסכוני ביותר. כתוצאה מכך, המשתנים מסוגלות־עצמית באוריינות־מידע ורגשות־חיוביים הוצאו מהמודל הסופי. המודל שהתקבל, המוצג באיור 1, הפגין התאמה מצוינת לנתונים [$\chi^2(8) = 12.08$, $p = .148$, $\chi^2/df = 1.51$, CFI = 0.99, RMSEA = .04, SRMR = .04].

טבלה 3 מציגה את תוצאות ניתוחי ה־Bootstrap שנערכו לבחינת המובהקות של אפקטים עקיפים ספציפיים. הנתיבים מפתיחות להשפעה־חברתית, למוטיבציה־נהנתנית ולרמת־ביצוע־מצופה נמצאו חיוביים ומובהקים, מה שמעיד כי רמות גבוהות של פתיחות קשורות לציונים גבוהים יותר במדדי ההשפעה־החברתית, המוטיבציה־הנהנתנית ורמת־הביצוע־המצופה. הנתיבים מהשפעה־חברתית, מוטיבציה־נהנתנית, רמת־ביצוע־מצופה ורמת־מאמץ־מצופה לשימוש ביישומי GenAI נמצאו מובהקים; ציונים גבוהים יותר בהשפעה־חברתית ובמוטיבציה־נהנתנית, לצד ציונים נמוכים יותר ברמת־ביצוע־מצופה וברמת־מאמץ־מצופה, נמצאו קשורים באופן מובהק להסתברות גבוהה יותר לשימוש בטכנולוגיה.

בהמשך נבחנו האפקטים העקיפים של פתיחות על השימוש ביישומי GenAI. האפקטים העקיפים בתיווך השפעה־חברתית ומוטיבציה־נהנתנית נמצאו מובהקים, אך לא כך לגבי האפקט העקיף בתיווך רמת־ביצוע־מצופה. התוצאות העלו כי רמה גבוהה של פתיחות קשורה באופן חיובי לציונים גבוהים יותר בהשפעה־חברתית ובמוטיבציה־נהנתנית, ואלה בתורם הובילו להסתברות גבוהה יותר ומובהקת לשימוש ביישומי GenAI. בנוסף, נמצאו אפקטים עקיפים של גיל, מגדר והשכלה על השימוש בטכנולוגיה בתיווך מוטיבציה־נהנתנית (אפקטים אלו לא שוערו מראש): גיל צעיר, מגדר נשי והשכלה אקדמית נמצאו קשורים באופן מובהק לציון גבוה יותר במוטיבציה־נהנתנית, וזה האחרון נקשר להסתברות גבוהה יותר לשימוש ב־GenAI. האפקטים העקיפים של גיל ומגדר על השימוש ביישומי GenAI בתיווך רמת־מאמץ־מצופה נמצאו אף הם מובהקים. נמצא כי גיל צעיר ומגדר נשי קשורים לציון נמוך יותר ברמת־המאמץ־המצופה, מה שנקשר להסתברות גבוהה יותר לשימוש בטכנולוגיה. לסיכום, המודל הסביר 36% מהשונות בשימוש ביישומי GenAI.

דיון

מחקר זה ביקש להבין את ההיבטים המגוונים הקשורים לשימוש בטכנולוגיה המתהווה של יישומי GenAI. **השערה 1** הניחה כי קיים קשר חיובי בין השפעה־חברתית לבין השימוש ביישומי GenAI. הממצאים איששו השערה זו והצביעו על כך שמשתתפים בעלי מדדים גבוהים יותר של השפעה־חברתית נטו יותר להשתמש ביישומי GenAI, ממצא העולה בקנה אחד עם מסקנותיהם של מחקרים קודמים (Strzelecki, 2023). נראה כי השפעה־חברתית, כגון שיתוף בחוויות חיוביות והמלצות, עשויה לעודד אנשים נוספים לאמץ את השימוש בכלים אלו. ממצאי מודל הנתיבים מוסיפים ומצביעים על כך שהשפעה־חברתית עשויה לתפקד כגורם מתווך המקשר בין פתיחות להתנסויות לבין השימוש ב־GenAI. הניתוח מניח כי עלייה ברמת הפתיחות קשורה לרמה מוגברת של השפעה־חברתית, וזו בתורה עשויה לטפח שימוש רב יותר בטכנולוגיה. ממצאים אלה מתיישבים עם מחקרים קודמים שבחנו אסטרטגיות של השפעה־חברתית וקשרו בין פתיחות לבין נטייתם של פרטים להשתכנע בכדאיות השימוש בטכנולוגיות מתפתחות (Oyibo and Vassileva, 2019).

השערה 2 הניחה קשר חיובי בין מוטיבציה־נהנתנית לבין השימוש ביישומי GenAI, והשערה זו זכתה לתמיכה אמפירית. ממצא זה מרמז כי משתתפים בעלי רמות גבוהות של מוטיבציה־נהנתנית נוטים יותר

להשתמש ב־GenAI. באופן ספציפי, מוטיבציה־נהנתנית התגלתה כמשתנה בעל הקורלציה הגבוהה ביותר עם השימוש ב־GenAI בהשוואה למשתנים האחרים שנבחנו במחקר. ממצא זה עולה בקנה אחד עם מחקרי עבר (Gursoy et al., 2019; Kelly et al., 2023), ומדגיש את חשיבותם של ההנאה והסיפוק כגורמי מפתח באימוץ טכנולוגיות חדשות כמו GenAI. נראה כי הבינה המלאכותית היוצרת נתפסת על ידי אנשים לא רק למטרות תועלתניות אלא גם לצורכי בידור, כפי שמעידות הרמות הגבוהות של מוטיבציה־נהנתנית שנצפו במחקר זה. ממצאי מודל ניתוח הנתיבים מצביעים על כך שמוטיבציה־נהנתנית נמצאה כגורם מתווך גם בקישור בין פתיחות־להתנסויות, גיל, מגדר והשכלה לבין השימוש ביישומי GenAI. משמעות הדבר היא כי פתיחות גבוהה יותר להתנסויות, גיל צעיר יותר, מגדר נשי והשכלה אקדמית גבוהה קשורים באופן חיובי לציונים גבוהים יותר של מוטיבציה־נהנתנית, ואלה בתורם קשורים לשימוש ביישומי GenAI. מחקרים קודמים לא מצאו קשרים דומים (Tamilmani et al., 2019), מה שמעיד על מקוריותן של תוצאות אלו ומעלה את האפשרות כי לשימוש ביישומי GenAI קיימים מאפיינים ייחודיים הנבדלים מטכנולוגיות שקדמו לה. אנשים הפתוחים להתנסויות חדשות נוטים להפגין עניין רב יותר בחדשנות ובאסתטיקה, בעוד שאנשים צעירים מחפשים לעיתים קרובות הנאה ובידור; שני הגורמים הללו קשורים באופן טבעי למוטיבציה־נהנתנית גבוהה יותר. יתרה מכך, הפשטות של יישומי GenAI עשויה להסביר את הקשר עם מוטיבציה־נהנתנית גבוהה יותר בקרב נשים. עם זאת, הקשר שבין השכלה אקדמית למוטיבציה־נהנתנית עדיין דורש מחקר נוסף כדי לבסס את המסקנות.

באשר **להשערה 3**, נמצא כי רמות גבוהות של מאמץ צפוי קשורות להסתברות נמוכה יותר לשימוש ביישומי GenAI. ממצא זה עקבי עם תוצאות של מחקרים קודמים (Cao, 2021; Chatterjee & Bhattacharjee, 2020; Hu *et al*., 2020; Raza *et al*., 2022), אשר הראו כי אנשים המצפים למאמץ ניכר נוטים פחות לאמץ טכנולוגיות. המשמעות היישומית של ממצא זה עשויה להיות קידום יישומי GenAI כחלופות החוסכות זמן ומאמץ, לצד פיתוח והכשרה שיפחיתו את חששות המשתמשים בנוגע למאמץ הנדרש, במיוחד בקרב אלו התופסים זאת כבעיה פוטנציאלית. מודל הנתיבים אף הצביע על כך שגיל צעיר ומגדר נשי קשורים לרמות נמוכות יותר של מאמץ צפוי ואף לשימוש רב יותר בטכנולוגיה, ממצא שמאפשר להתאים את ההכשרה למאפיינים הייחודיים של כל אוכלוסייה.

בניגוד לכך, **השערה 4**, אשר עסקה בקשר בין רמת־הביצוע־המצופה לבין השימוש ביישומי GenAI, לא זכתה לאישוש, שכן ערכים גבוהים של רמת־הביצוע־המצופה לא הובילו להסתברות מוגברת לשימוש. ממצא בלתי צפוי זה עומד בסתירה למחקרים קודמים בנוגע לעמדות כלפי טכנולוגיות ושימוש בהן (Aharony, 2015b; Cao et al., 2021; Strzelecki, 2023), ומעלה את האפשרות כי אימוץ יישומי GenAI אינו קשור באופן הדוק לתפיסת הביצועים כפי שנצפה בגלי טכנולוגיה קודמים. נתון זה מחייב בחינה נוספת במטרה לזקק את מודלי הקבלה הקיימים ולהתאימם לטכנולוגיה ייחודית זו. יתר על כן, מודל הנתיבים הצביע על קשר מורכב שלפיו בעלי השכלה אקדמית מצפים לביצועים פחותים, מה שמוביל לשימוש מופחת, אולם בשל המתאמים הנמוכים נדרשת בחינה מעמיקה יותר ליישוב האי־ודאות המחקרית.

השערה 5, אשר הניחה קשר בין רגשות־חיוביים לבין השימוש ביישומי GenAI, אוששה אף היא. ממצא זה מרמז כי פרטים החווים רגשות־חיוביים יותר כלפי GenAI נוטים יותר להשתמש בה. תוצאה זו עולה בקנה אחד עם מחקרי עבר (Beaudry & Pinsonneault, 2010; Gursoy et al., 2019; Valor et al., 2022) אשר גרסו כי רגשות־חיוביים כלפי טכנולוגיה ממלאים תפקיד מכריע בקבלתה. רגשות־חיוביים קשורים באופן מובהק לתהליכי קבלת ההחלטות של הפרט, ולפיכך תחושות חיוביות כלפי טכנולוגיה דוגמת GenAI עשויות לטפח עמדה מזמינה ומקבלת, ובכך להעלות את הסבירות לשימוש בה. יצוין כי ניתוח הנתיבים לא

מצא זיקה בין רגשות־חיוביים כלפי בינה מלאכותית לבין השימוש ביישומי GenAI, וזאת משום שהמתאם נמצא כלא מובהק בתוך מערך המודל הכולל.

השערה 6 הניחה קשר בין פתיחות ובין שימוש ב־GenAI, והתוצאות אכן אישרו קשר זה. נמצא כי אנשים בעלי רמות גבוהות יותר של פתיחות נוטים יותר להשתמש בטכנולוגיות של GenAI. מתאם זה תומך במחקרים קודמים (Aharony, 2015a; Seibert et al., 2021), אשר הצביעו על פתיחות כגורם משמעותי בקבלה ובאימוץ של חידושים טכנולוגיים שונים. קשר זה מדגיש את חשיבותם של מאפייני אישיות בשימוש בטכנולוגיה, תוך הבלטת האופן שבו הבדלים בין־אישיים בתכונת הפתיחות עשויים להיות קשורים לנטייה לאמץ טכנולוגיות חדשות ומתהוות. בנוסף, ניתוח הנתיבים הראה כי הקשר בין פתיחות לבין השימוש ביישומי GenAI מתווך על ידי השפעה־חברתית ומוטיבציה־נהנתנית. משמעות הדבר היא שציונים גבוהים יותר של פתיחות להתנסויות קשורים לציונים גבוהים יותר של השפעה־חברתית ומוטיבציה־נהנתנית, ואלה נקשרים להסתברות גבוהה יותר לשימוש ב־GenAI.

באופן דומה, **השערה 7,** אשר חזתה קשר בין מסוגלות־עצמית באוריינות־מידע לבין השימוש ביישומי GenAI, זכתה לאישוש במחקר זה. הממצאים מעלים כי פרטים בעלי רמות גבוהות יותר של מסוגלות־עצמית באוריינות־מידע נוטים יותר להשתמש ב־GenAI. תוצאות אלו עשויות לרמוז על כך שבעלי תפיסה גבוהה של מסוגלותם באוריינות־מידע, פיתחו מיומנויות של הערכת אמינות, זיהוי הטיות, הבחנה בין עובדות לבין דעות וסינון של התוצרים המופקים מיישומי GenAI. בנוסף, ציון גבוה במשתנה זה, משקף אמונה רבה יותר של הפרט ביכולתו ללמוד ולאמץ טכנולוגיות פורצות דרך דוגמת GenAI. עם זאת, כאשר המשתנה נבחן במסגרת מודל הנתיבים הכולל, תרומתו הישירה לשימוש נותרה לא מובהקת. ממצא זה עשוי להעיד כי מסוגלות־עצמית באוריינות־מידע מהווה תשתית קוגניטיבית כללית להתמודדות עם סביבות מידע מורכבות, אך השימוש בפועל ביישומי GenAI מוסבר במידה רבה יותר באמצעות משתני קבלה מיידיים וחווייתיים, כגון מוטיבציה־נהנתנית, השפעה־חברתית ורמת־המאמץ־המצופה. במילים אחרות, ייתכן שמשתמשים בעלי תחושת מסוגלות־עצמית גבוהה באוריינות־מידע מחזיקים בנטייה כללית טובה יותר להתמודדות עם מידע דיגיטלי, אולם ההחלטה להשתמש בפועל ב־GenAI מושפעת יותר מן החוויה הנתפסת של השימוש, מן ההקשר החברתי ומן המאמץ הנתפס.

מעבר להשערות המחקר, נרשמו ממצאים נוספים הנוגעים למשתני הגיל, המגדר וההשכלה. גיל קשור ישירות ובעקיפין לשימוש ביישומי GenAI. ניתוח המתאמים חושף קשר ישיר ומובהק בין גיל לבין השימוש ביישומים אלו, המצביע על כך שצעירים נוטים להשתמש בהם בתדירות גבוהה יותר. ממצא זה עולה בקנה אחד עם מחקרי עבר המעידים כי קבוצות גיל צעירות נוטות להחזיק בכוונות התנהגותיות גבוהות יותר ביחס לאימוץ טכנולוגיות (Morris et al., 2005; Venkatesh et al., 2003).

כפי שהוצג במודל ניתוח הנתיבים, האפקט העקיף המקשר בין גיל לבין השימוש ביישומי GenAI מתווך על ידי מוטיבציה־נהנתנית; פירוש הדבר שצעירים חווים יותר הנאה וסיפוק מהשימוש ביישומים אלו, עובדה המגבירה את סבירות השימוש שלהם. יתרה מכך, המודל חושף נתיב עקיף נוסף: השפעת הגיל על השימוש מתווכת על ידי רמת־המאמץ־המצופה. נמצא כי משתמשים מבוגרים יותר תופסים את המאמץ הנדרש לשימוש בטכנולוגיה כגבוה יותר, מה שמוביל בתורו לסבירות שימוש נמוכה יותר. פער גילים זה בשימוש ביישומי GenAI מדגיש את הצורך להימנע מהשארת האוכלוסייה המבוגרת מאחור, וזאת באמצעות הכשרות ייעודיות, התאמת חוויית המשתמש, העלאת מודעות וצמצום תפיסת המאמץ הכרוכה בתפעול הטכנולוגיה.

באשר למגדר, לא נמצא קשר ישיר בין מגדר לבין השימוש ביישומי GenAI. עם זאת, ניתוח הנתיבים חשף אפקט עקיף המצביע על כך שמגדר קשור לשימוש דרך רמת־המאמץ־המצופה, כאשר גברים תפסו חסמי מאמץ גבוהים יותר בהשוואה לנשים. תוצאה זו סותרת מחקרים קודמים (Venkatesh et al., 2003), שמצאו כי לנשים יש בדרך כלל רמת־מאמץ־מצופה גבוהה יותר בנוגע לאימוץ טכנולוגי. ייתכן שניתן ליישב סתירה זו לאור מחקר קודם (Morris et al., 2005), שמצא כי הפער המגדרי הולך ומצטמצם בקרב בני הגילים הצעירים. הסבר אפשרי נוסף הוא שהבינה המלאכותית היוצרת מציבה חסמי מאמץ שונים בהשוואה לטכנולוגיות שנחקרו בעבר; כטכנולוגיה הממוקדת בשפה טבעית ובכישורים מילוליים, היא עשויה לדרוש פחות מאמץ טכני ובכך לסייע במיתון ההבדלים המגדריים המסורתיים. נדרש מחקר נוסף כדי להבין לעומק את הסיבות לממצאים סותרים אלו בנוגע להבדלים מגדריים.

לבסוף, נמצא כי להשכלה אקדמית יש קשר לשימוש ביישומי GenAI, הן ישירות והן בעקיפין. הקשר הישיר מצביע על מתאם מובהק המרמז כי בעלי רקע אקדמי נוטים להשתמש בטכנולוגיה זו יותר. ממצא זה אינו מפתיע, שכן השימוש ביישומים אלו דורש רמה מסוימת של אוריינות, המצופה מבעלי השכלה גבוהה. יתרה מכך, ניתוח הנתיבים חשף כי להשכלה אקדמית יש גם קשר עקיף עם מוטיבציה־נהנתנית, המתווכת את הקשר לשימוש ביישומי GenAI. משתתפים בעלי השכלה אקדמית היו בעלי מוטיבציה־נהנתנית גבוהה יותר מאלו ללא השכלה אקדמית, ואף נמצאה סבירות גבוהה יותר שישתמשו ב־GenAI. הסבר אפשרי לכך הוא שעבור משתמשים בעלי רקע אקדמי ההלימה בין יכולות הטכנולוגיה לבין צורכיהם האקדמיים מגבירה את תחושת ההנאה והסיפוק בעת השימוש, ובכך מחזקת את המוטיבציה־הנהנתנית ומעודדת שימוש תדיר יותר. עם זאת, נדרשות ראיות נוספות בנושא זה כדי לגבש מסקנה נחרצת.

סיכום

מחקר זה מצא כי מוטיבציה־נהנתנית, השפעה־חברתית ורמת־מאמץ־מצופה מתווכים את הזיקה שבין תכונות אישיות, משתני רקע והשימוש ביישומי GenAI. הממצאים מציעים פרספקטיבה חדשנית המרמזת כי כלי GenAI מאומצים דרך מנגנונים הנבדלים מאלו שהניעו אימוץ טכנולוגיות קודמות, תוך מתן דגש פחות על תועלת ודגש רב יותר על הנאה ונורמות חברתיות. דפוס ייחודי זה מדגיש את הצורך במחקר נוסף מבוסס תיאוריה שיזקק את המודלים הקיימים תוך התחשבות בדינמיקה הייחודית של השימוש ב־GenAI. התוצאות האמפיריות של ניתוחי המתאמים אישרו כי שש מתוך שבע ההשערות המקשרות בין המשתנים הבלתי תלויים לשימוש ביישומי GenAI זכו לתמיכה. היוצא מן הכלל היה משתנה רמת־הביצוע־המצופה, שהראה קשר הפוך לשימוש – ממצא המנוגד לציפיות המבוססות על מחקרי עבר בתחום קבלת הטכנולוגיה. תפקידה המרכזי של המוטיבציה־הנהנתנית במודל השימוש היה אף הוא בלתי צפוי, והוא מבליט את המשיכה החווייתית המיוחדת של כלי הבינה המלאכותית היוצרת. נראה כי במקום להימדד בעיקר על פי תועלתם או קלות השימוש בהם, כלי הבינה המלאכותית היוצרת מאומצים בשל היותם מהנים מהותית, חדשניים או מעוררים מבחינה יצירתית עבור המשתמש. ממצאים אלו מדגישים את הנחיצות בפיתוח מסגרות תיאורטיות מעודכנות שיתנו מענה למאפיינים הייחודיים ולמניעי השימוש הקשורים ביישומי GenAI.

השלכות יישומיות למקבלי החלטות

תוצאות מחקר זה עשויות להציע כיווני חשיבה ראשוניים עבור גורמים העוסקים בהטמעה, הדרכה והנגשה של יישומי GenAI. בפרט, הממצאים מצביעים על כך ששימוש בטכנולוגיה קשור לא רק לתפיסת התועלת שלה, אלא גם למוטיבציה־נהנתנית, להשפעה־חברתית ולרמת־המאמץ־המצופה. לפיכך, תוכניות הדרכה או התערבויות ראשוניות עשויות להפיק תועלת מהדגשת חוויית שימוש חיובית, מהפחתת תחושת המאמץ ומהצגת דוגמאות שימוש רלוונטיות לקבוצות משתמשים שונות. עם זאת, מכיוון שמדובר במחקר חתך המבוסס על דיווח עצמי, יש לראות בהשלכות אלו כיווני יישום אפשריים בלבד, ויש להמשיך לבדוק את הכיוונים הללו במחקרים עתידיים.

מגבלות המחקר והצעות למחקר עתידי

למחקר הנוכחי מספר מגבלות. מחקר זה הוא מחקר חלוצי בתחומו ועל כן נדרשת חקירה מעמיקה ונוספת של הנושא. כיווני מחקר עתידיים פוטנציאליים עשויים לכלול מחקרים ארוכי טווח במטרה לבחון את השינוי בדפוסי השימוש המתרחשים לאורך זמן, ככל שהטכנולוגיה עצמה משתכללת והמשתמשים הופכים מנוסים ומיומנים יותר.

מאחר שמחקר זה נסמך על שיטות מחקר כמותיות בלבד, שילוב של שיטות איכותניות בעתיד, דוגמת ראיונות עומק או קבוצות מיקוד, עשוי לסייע בהפקת תובנות מעמיקות יותר באשר לסיבות העומדות בבסיס המסקנות שהתקבלו.

בנוסף, המחקר מתבסס על דיווח עצמי של המשתתפים בנוגע להרגלי השימוש ותפיסות הקבלה שלהם, דבר העלול להוביל להטיות מחקריות כגון רצייה חברתית או דיווח עצמי שאינו מדויק דיו. לפיכך, מחקר עתידי עשוי להפיק תועלת משמעותית ממדידה של התנהגות בפועל בסביבה טבעית.

מגבלה נוספת נוגעת לאופן גיוס המשתתפים באמצעות פאנל אינטרנטי מסחרי. אף שפאנלים מסוג זה מאפשרים גישה יעילה לאוכלוסייה רחבה ומגוונת, ההשתתפות בהם מבוססת על הרשמה מוקדמת ולעיתים גם על תגמול עבור מילוי סקרים. לפיכך, ייתכנו הטיות של בחירה עצמית, מוטיבציה חיצונית להשתתפות, ייצוג־יתר של אנשים המורגלים במענה לסקרים מקוונים וייצוג־חסר של אוכלוסיות בעלות נגישות דיגיטלית נמוכה. מגבלות אלו עשויות להשפיע על תוקף ההכללה של הממצאים, ויש להביאן בחשבון בפרשנות התוצאות.

התאמת כלי ה־AIDUA להקשר של שימוש ביישומי GenAI בקרב דוברי עברית בישראל אפשרה לבחון את קבלת השימוש ב־GenAI בהקשר טכנולוגי, לשוני ותרבותי רלוונטי לאוכלוסיית המחקר. יחד עם זאת, במסגרת תהליך ההתאמה נערכה בחינה אמפירית של מבנה הפריטים, ובעקבותיה הוסרו חלק מהפריטים המקוריים. אף שתהליך זה חיזק את ההתאמה של הסולמות למחקר הנוכחי ואת בהירותם האמפירית, יש להביא בחשבון כי הגרסה שבה נעשה שימוש היא גרסה מותאמת של המדד, ולכן יש להיזהר בהשוואה הישירה למחקרים שהתבססו על הנוסח המקורי של הכלי. מחקרים עתידיים יוכלו להמשיך לבסס את תוקפה של הגרסה העברית המותאמת באמצעות ניתוח גורמים מאשש ומדגמים נוספים.

המשתנים שנבחרו למחקר זה נגזרו מתוך בולטותם במחקרים קודמים שעסקו בטכנולוגיות עבר, וזאת במטרה להבטיח המשכיות תיאורטית. עם זאת, ייתכן שגישה ממוקדת זו הובילה להדרה של משתנים רלוונטיים אחרים. ככל שתחום השימוש ביישומי GenAI ימשיך להתפתח, על מחקרים עתידיים להרחיב את היריעה המחקרית ולכלול מבנים תיאורטיים נוספים הידועים כרלוונטיים בתחומים משיקים, וזאת כדי לגבש הבנה מקיפה ורחבה יותר של התנהגות המשתמשים.

התייחסות למגבלות האמורות במחקרי המשך עשויה לחזק את הבנת המאפיינים והדינמיקה של השימוש ביישומי GenAI. כיווני מחקר אלו עשויים לתרום משמעותית להבנת המערך המורכב של קבלה ושימוש בטכנולוגיה זו.

מקורות

Aharony, N. (2015a). An exploratory study on factors affecting the adoption of cloud computing by information professionals. *The Electronic Library, 33*(2), 308-323. https://doi.org/10.1108/EL-09-2013-0163

Aharony, N. (2015b). Factors affecting the adoption of e-books by information professionals. *Journal of Librarianship and Information Science, 47*(2), 131-144. https://doi.org/10.1177/0961000614532120

Aharony, N., & Gazit, T. (2019). Factors affecting students' information literacy self-efficacy. *Library Hi Tech, 37*(2), 170-183. https://doi.org/10.1108/LHT-10-2018-0154

Aharony, N., & Prebor, G. (2015). Librarians' and information professionals' perspectives towards discovery tools – An exploratory study. *The Journal of Academic Librarianship, 41*(4), 429-440. https://doi.org/10.1016/j.acalib.2015.05.003

Aharony, N., & Shonfeld, M. (2015). ICT use: Educational technology and library and information science students perspectives-an exploratory study. *Interdisciplinary Journal of e-Skills and Life Long Learning, 11*, 191-207. https://doi.org/10.28945/2323

Alagöz Hamzaj, Y. (2025). Generative AI acceptance among future educators: Personality and behavioral insights. *Education and Information Technologies.* https://doi.org/10.1007/s10639-025-13678-3

American Library Association. (1989). *American library association presidential committee on information literacy*. https://www.ala.org/acrl/publications/whitepapers/presidential

Arpaci, I., Kuşci, I., & Gibreel, O. (2025). The role of personality traits in predicting educational use of generative AI in higher education. *Scientific Reports, 15*, Article 25931. https://doi.org/10.1038/s41598-025-16339-0

Baabdullah, A.M. (2018). Consumer adoption of mobile social network games (M-SNGs) in Saudi-Arabia: The role of social influence, hedonic motivation, and trust. *Technology in Society, 53*, 91–102. https://doi.org/10.1016/j.techsoc.2018.01.004

Bandura, A. (1993). Perceived self-efficacy in cognitive development and functioning. *Educational psychologist, 28*(2), 117-148. https://doi.org/10.1207/s15326985ep2802_3

Bankins, S., Ocampo, A. C., Marrone, M., Restubog, S. L. D., & Woo, S. E. (2023). A multilevel review of artificial intelligence in organizations: Implications for organizational behavior research and practice. *Journal of Organizational Behavior, 45*(2), 159–182. https://doi.org/10.1002/job.2735

Beaudry, A., & Pinsonneault, A. (2010). "The Other Side of Acceptance": Studying the direct and indirect effects of emotions on information technology use. *MIS Quarterly, 34*(4), 689-710. https://doi.org/10.2307/25750701

Bentler, P. M., & Mooijaart, A. (1989). Choice of structural model via parsimony: A rationale based on precision. *Psychological Bulletin, 106*(2), 315–317. https://doi.org/10.1037/0033-2909.106.2.315

Brynjolfsson, E., Li, D., & Raymond, L. (2025). Generative AI at work. *The Quarterly Journal of Economics*, qjae044. https://doi.org/10.1093/qje/qjae044

Cao, G., Duan, Y., Edwards, J. S., & Dwivedi, Y. K. (2021). Understanding managers' attitudes and behavioral intentions towards using artificial intelligence for organizational decision-making. *Technovation,* 106, 102312. https://doi.org/10.1016/j.technovation.2021.102312

Chatterjee, S., & Bhattacharjee, K. K. (2020). Adoption of artificial intelligence in higher education: A quantitative analysis using structural equation modelling. *Education and Information Technologies, 25*, 3443-3463. https://doi.org/10.1007/s10639-020-10159-7

Chen, L. S. L., Kuan, C. J., Lee, Y. H., & Huang, H. L. (2011, June). Applicability of the UTAUT model in playing online game through mobile phones: Moderating effects of user experience. In *First International Technology Management Conference* (pp. 625-629). IEEE. https://doi.org/10.1109/ITMC.2011.5996035

Davis, F. D. (1989). Perceived usefulness, perceived ease of use, and user acceptance of information technology. *MIS quarterly, 13*(3), 319-340. https://doi.org/10.2307/249008

Deng, X., & Yu, Z. (2023). An extended hedonic motivation adoption model of TikTok in higher education. *Education and Information Technologies*, 1-23. https://doi.org/10.1007/s10639-023-11749-x

Deranty, J.-P., & Corbin, T. (2024). Artificial intelligence and work: A critical review of recent research from the social sciences. *AI & Society*, *39*(3), 675–691. https://doi.org/10.1007/s00146-022-01496-x

Deshen, M., & Aharony, N. (2026). Students' Artificial Intelligence (AI) literacy: An exploratory study. *Journal of Librarianship and Information Science,* 09610006261442178. https://doi.org/10.1177/09610006261442178

Deshen, M., Harari, R., & Aharony, N. (2026). Teachers' adoption of generative artificial intelligence (GenAI) in educational settings. *Cogent Education, 13*(1), 2624877. https://doi.org/10.1080/2331186X.2026.2624877

Farquhar, S., Kossen, J., Kuhn, L., & Gal, Y. (2024). Detecting hallucinations in large language models using semantic entropy. *Nature, 630*, 625–630. https://doi.org/10.1038/s41586-024-07421-0

Gaskin, J., James, M., & Lim, J. (2020). *Specific indirect effects, AMOS Estimand*. Gaskination's StatWiki. http://statwiki.gaskination.com/

Gursoy, D., Chi, O. H., Lu, L., & Nunkoo, R. (2019). Consumers' acceptance of artificially intelligent (AI) device use in service delivery. *International Journal of Information Management, 49*, 157-169. https://doi.org/10.1016/j.ijinfomgt.2019.03.008

Hair, J. F., Black, W. C., Babin, B. J., & Anderson, R. E. (2014). *Multivariate data analysis* (7th edition, Pearson New International Edition). Pearson Education Limited.

Halder, S., Roy, A., & Chakraborty, P. K. (2010). The influence of personality traits on information seeking behaviour of students. *Malaysian Journal of Library & Information Science, 15*(1), 41-53.

Hayes, A. F. (2022). *Introduction to mediation, moderation, and conditional process analysis: A regression-based approach* (3rd edition). The Guilford Press.

Hernández-Tamurejo, Á., Bužinskienė, R., Barbosa, B., Miceikienė, A., & Saura, J. R. (2025). Generative artificial intelligence use in the workplace: Implications for management practice. *Review of Managerial Science*. https://doi.org/10.1007/s11846-025-00949-z

Holzmann, P., Gregori, P., & Schwarz, E. J. (2025). Students' little helper: Investigating continuous-use determinants of generative AI and ethical judgment. *Education and Information Technologies, 30*(17), 24991–25011. https://doi.org/10.1007/s10639-025-13708-0

Hu, L. T., & Bentler, P. M. (1999). Cut off criteria for fit indexes in covariance structure analysis: Conventional criteria versus new alternatives. *Structural Equation Modeling, 6*(1), 1–55. https://doi.org/10.1080/10705519909540118

Hu, S., Laxman, K., & Lee, K. (2020). Exploring factors affecting academics' adoption of emerging mobile technologies – an extended UTAUT perspective. *Education and Information Technologies, 25*, 4615-4635. https://doi.org/10.1007/s10639-020-10171-x

Huynh, M.-T., & Aichner, T. (2025). In generative artificial intelligence we trust: Unpacking determinants and outcomes for cognitive trust. *AI & Society, 40*, 5849–5869. https://doi.org/10.1007/s00146-025-02378-8

Ivcevic, Z., & Grandinetti, M. (2024). Artificial intelligence as a tool for creativity. *Journal of Creativity, 34*, 100079. https://doi.org/10.1016/j.yjoc.2024.100079

Jang, M., Aavakare, M., Nikou, S., & Kim, S. (2021). The impact of literacy on intention to use digital technology for learning: A comparative study of Korea and Finland. *Telecommunications Policy, 45*(7), 102154. https://doi.org/10.1016/j.telpol.2021.102154

John, O. P., & Srivastava, S. (1999). The Big Five trait taxonomy: History, measurement, and theoretical perspectives. In: O. P. John & L. A. Pervin (Eds.). *Handbook of personality: Theory and research* (pp. 102–138). Guilford Press.

Kaiser, H. F. (1960). The application of electronic computers to factor analysis. *Educational and Psychological Measurement, 20*, 141–151. https://doi.org/10.1177/001316446002000116

Kelly, S., Kaye, S. A., & Oviedo-Trespalacios, O. (2023). What factors contribute to the acceptance of artificial intelligence? A systematic review. *Telematics and Informatics, 77*, 101925. https://doi.org/10.1016/j.tele.2022.101925

Kline, R. B. (2016). *Principles and practice of structural equation modeling* (4th ed.). Guilford Press.

Korchak, A., Al Murshidi, G., Getman, A., Raouf, N., Arshe, M., Al Meheiri, N., Shulgina, G., & Costley, J. (2025). The role of social influence in generative artificial intelligence ChatGPT adoption intentions among undergraduate and graduate students. *Innovations in Education and Teaching International, 62*(5), 1559-1573. https://doi.org/10.1080/14703297.2025.2496942

Kurbanoğlu, S. (2003). Self-efficacy: A concept closely linked to information literacy and lifelong learning. *Journal of Documentation, 59* (6), 635–646. https://doi.org/10.1108/00220410310506295

Kurbanoğlu, S., Akkoyunlu, B., & Umay, A. (2006). Developing the information literacy self-efficacy scale. *Journal of Documentation, 62*(6), 730-743. https://doi.org/10.1108/00220410610714949

Lim, J. S., Shin, D., Lee, C., Kim, J., & Zhang, J. (2025). The role of user empowerment, AI hallucination, and privacy concerns in continued use and premium subscription intentions: An extended technology acceptance model for generative AI. *Journal of Broadcasting & Electronic Media, 69*(3), 183–199. https://doi.org/10.1080/08838151.2025.2487679

Liu, J. (2024). ChatGPT: Perspectives from human-computer interaction and psychology. *Frontiers in Artificial Intelligence, 7,* 1418869. https://doi.org/10.3389/frai.2024.1418869

Marangunić, N., & Granić, A. (2015). Technology acceptance model: a literature review from 1986 to 2013. *Universal access in the information society, 14*, 81-95. https://doi.org/10.1007/s10209-014-0348-1

Maruping, L. M., Bala, H., Venkatesh, V., & Brown, S. A. (2017). Going beyond intention: Integrating behavioral expectation into the unified theory of acceptance and use of technology. *Journal of the Association for Information Science and Technology, 68*(3), 623-637. https://doi.org/10.1002/asi.23699

Menon, D., Zhang, T., Siau, K., & Zirar, A. (2024). ChatGPT adoption and anxiety: A cross-country analysis utilising the unified theory of acceptance and use of technology. *Studies in Higher Education, 49*(5), 855–870. https://doi.org/10.1080/03075079.2024.2333937

McCrae, R. R., & Costa Jr, P. T. (1988). Do parental influences matter? A reply to Halverson. *Journal of Personality, 56*(2), 445-449. https://doi.org/10.1111/j.1467-6494.1988.tb00896.x

McCrae, R. R., & Costa Jr, P. T. (1992). Discriminant validity of NEO-PIR facet scales. *Educational and psychological measurement, 52*(1), 229–237.

https://doi.org/10.1177/001316449205200128

Morris, M. G., Venkatesh, V., & Ackerman, P. L. (2005). Gender and age differences in employee decisions about new technology: An extension to the theory of planned behavior. *IEEE transactions on engineering management*, *52*(1), 69-84. https://doi.org/10.1109/TEM.2004.839967

Nikou, S., De Reuver, M., & Mahboob Kanafi, M. (2022). Workplace literacy skills – How information and digital literacy affect adoption of digital technology. *Journal of Documentation, 78*(7), 371-391. https://doi.org/10.1108/JD-12-2021-0241

Oluwajana, D., Idowu, A., Nat, M., Vanduhe, V., & Fadiya, S. (2019). The adoption of students' hedonic motivation system model to gamified learning environment. *Journal of theoretical and applied electronic commerce research, 14*(3), 156-167. https://doi.org/10.4067/S0718-18762019000300109

Oyibo, K., & Vassileva, J. (2019). The relationship between personality traits and susceptibility to social influence. *Computers in Human Behavior, 98*, 174-188. https://doi.org/10.1016/j.chb.2019.01.032

Park, J., Woo, S. E., & Kim, J. (2024). Attitudes towards artificial intelligence at work: Scale development and validation. *Journal of Occupational and Organizational Psychology*, *97*(3), 920–951. https://doi.org/10.1111/joop.12502

Raza, S. A., Qazi, Z., Qazi, W., & Ahmed, M. (2022). E-learning in higher education during COVID-19: Evidence from blackboard learning system. *Journal of Applied Research in Higher Education, 14*(4), 1603-1622. https://doi.org/10.1108/JARHE-02-2021-0054

Sabag-Ben Porat, C. (2025). AI perceptions across technological generations: Utopian and dystopian views uniting baby boomers and gen Z in Israel. *Israel Affairs*, 1-24. https://doi.org/10.1080/13537121.2025.2542791 https://doi.org/10.1007/s11528-025-01096-8

Seibert, D., Godulla, A., & Wolf, C. (2021). Understanding how personality affects the acceptance of technology: A literature review. *Media and Communication*, 1-24. https://nbn-resolving.org/urn:nbn:de:0168-ssoar-75164-7

Shrout, P. E., & Bolger, N. (2002). Mediation in experimental and nonexperimental studies: New procedures and recommendations. *Psychological Methods, 7*(4), 422–445. https://doi.org/10.1037/1082-989X.7.4.422

Spisak, J. R. (2023). Information literacy self-efficacy versus performance: Secondary students. *Journal of Librarianship and Information Science, 55*(2), 348-357. https://doi.org/10.1177/09610006221081847

Strzelecki, A. (2023). To use or not to use ChatGPT in higher education? a study of students' acceptance and use of technology. *Interactive Learning Environments*, *32*(9), 5142–5155. https://doi.org/10.1080/10494820.2023.2209881

Su, J., Wang, Y., Liu, H., Zhang, Z., Wang, Z., & Li, Z. (2025). Investigating the factors influencing users' adoption of artificial intelligence health assistants based on an extended UTAUT model. *Scientific Reports*, *15*, Article 18252. https://doi.org/10.1038/s41598-025-01897-0

Subhani, F., Khan, S. A., Sandhu, M. A., & Shahzad, M. F. (2025). What factors affect the adoption intention and actual use of ChatGPT in higher education? The moderating role of academic integrity. *TechTrends*, 69(5), 1056–1071.

Tamilmani, K., Rana, N. P., Prakasam, N., & Dwivedi, Y. K. (2019). The battle of Brain vs. Heart: A literature review and meta-analysis of "hedonic motivation" use in UTAUT2. *International Journal of Information Management, 46*, 222-235. https://doi.org/10.1016/j.ijinfomgt.2019.01.008

Valor, C., Antonetti, P., & Crisafulli, B. (2022). Emotions and consumers' adoption of innovations: An integrative review and research agenda. *Technological Forecasting & Social Change*, *179*, 121609. https://doi.org/10.1016/j.techfore.2022.121609

Vasiliu, V., & Yavetz, G. (2026). Who's afraid of AI? Socio-technological perspectives on artificial intelligence in the workforce: An Israeli case study. *Aslib Journal of Information Management*, *78*(1), 49-64. https://doi.org/10.1108/AJIM-12-2023-0562

Venkatesh, V., & Davis, F. D. (2000). A theoretical extension of the technology acceptance model: Four longitudinal field studies. *Management science, 46*(2), 186-204. https://doi.org/10.1287/mnsc.46.2.186.11926

Venkatesh, V., Morris, M. G., Davis, G. B., & Davis, F. D. (2003). User acceptance of information technology: Toward a unified view. *MIS Quarterly*, 425-478. https://doi.org/10.2307/30036540

Venkatesh, V., Thong, J. Y., & Xu, X. (2012). Consumer acceptance and use of information technology: Extending the unified theory of acceptance and use of technology. *MIS Quarterly*, 157-178. https://doi.org/10.2307/41410412

Wang, H., Dang, A., Wu, J. Y., & Mac, S. (2025). Exploring trust in generative AI for higher education institutions: A systematic literature review focused on educators. *Humanities and Social Sciences Communications*, *12*, Article 1099. https://doi.org/10.1057/s41599-025-06253-1

Yin, M., Jiang, S., & Niu, X. (2024). Can AI really help? The double-edged sword effect of AI assistant on employees' innovation behavior. *Computers in Human Behavior*, *150,* 107987. https://doi.org/10.1016/j.chb.2023.107987

Yu, C. W., Chao, C. M., Chang, C. F., Chen, R. J., Chen, P. C., & Liu, Y. X. (2021). Exploring behavioral intention to use a mobile health education website: An extension of the UTAUT 2 model. *SAGE Open*, *11*(4), 21582440211055721. https://doi.org/10.1177/21582440211055721