

חיתום אשראי צרכני על סמך עיבוד מידע אלגוריתמי – היש סיבה לחשוש מהפליה אסורה?

מאת

רות פלאטו־שנער* ומעיין פרל**

תקציר

המאמר עוסק באופן שבו מתקבלות החלטות בנוגע להעמדת אשראי צרכני בידי מלווים בנקאיים וחוץ-בנקאיים בישראל, פעולה המכונה בעגה המקצועית "חיתום אשראי". לאור מהפכת המידע ופיתוחן של טכנולוגיות ניתוח נתוני עתק מתקדמות, יותר ויותר נותני אשראי אינם מסתפקים במשטר השיתוף בנתוני אשראי המבוסס על מאגר לאומי של נתוני אשראי בבנק ישראל. הם מבצעים חיתום אשראי אוטומטי בהתבסס על כלים של בינה מלאכותית, המשקללים מגוון עצום ורב של נתוני מידע, לרבות מידע שאינו פיננסי כלל.

לצד היתרונות של שימוש בכלים של בינה מלאכותית, ובראשם דיוק ויעילות, המאמר מצביע על סיכון ממשי של הפליה בין לקוחות ושל פגיעה באוכלוסיות המוחלשות, הן בשל טיב המידע המשמש לבניית המודלים והן בשל שיטות לעיבוד המידע. בחינת הדין המצוי, תוך השוואה לרגולציה הקיימת במדינת אחרות, מעלה כי אין בו כדי לספק מענה הולם לצמצום הסיכון האמור. לאור זאת, ומתוך הבנה כי חקיקה ראשית המסדירה את השימוש בבינה מלאכותית לא תתקבל בקרוב, המאמר קורא לרגולטורים הפיננסיים להציב כמה דרישות למלווים הכפופים לפיקוחם, במטרה לצמצם את הסיכון האמור: ביצוע בקרות פנימיות והערכות תקופתיות, ודיווח על תוצאות הבדיקות; קיום מעורבות אנושית בהליך החיתום האוטומטי; ושימוש במודלים בנייהסבר בלבד. כמו כן המאמר מציע כמה הצעות כדי להקל על מצוקתם של מודרי האשראי.

* רות פלאטו־שנער היא פרופסור מן המניין, מייסדת וראשת המרכז לדיני בנקאות ורגולציה פיננסית, המכללה האקדמית נתניה. היא מכהנת בתפקידים הבאים: סגנית יו"ר הוועדה המייעצת לממונה על שוק ההון, ביטוח וחיסכון; יו"ר הוועדה המייעצת לממונה על שוק ההון, ביטוח וחיסכון בתפקידו כמפקח על שירותים פיננסיים מוסדרים; יו"ר הוועדה המייעצת לממונה על השיתוף בנתוני אשראי; חברת הוועדה המייעצת לנגיד בנק ישראל בענייני בנקאות. הדעות המובאות במאמר זה הן דעותיה הפרטיות ואינן מייצגות איזשהו מהגופים האמורים. המידע הכלול במאמר נאסף ממקורות פומביים ואינו כולל מידע שהגיע לכותבת בתוקף תפקידה האמורים.

** מעיין פרל היא מרצה בכירה, המכללה האקדמית נתניה.

554	מבוא
559	א. רקע לחיתום אשראי אלגוריתמי בישראל: משטר השיתוף בנתוני אשראי
561	1. מאגר נתוני האשראי בבנק ישראל
567	2. מערכת הבנקאות הפתוחה
569	ב. קבלת החלטות בנוגע להעמדת אשראי צרכני: מקומם של מודלים אלגוריתמיים
569	1. ניתוח אלגוריתמי של נתוני עתק לצורך הערכת סיכון אשראי
571	2. מודלים לדירוג אשראי
575	3. מודלים לחיתום אשראי
578	ג. הפליה בחיתום אשראי
578	1. הפליה אסורה מול הבחנה מותרת
580	2. חיתום אשראי אלגוריתמי: הפליה מול הכלה
582	3. הפליה היסטורית המובנית בפריטי המידע
588	4. הפליה שנובעת משיטת ניתוח המידע
589	ד. חיתום אשראי אלגוריתמי: המסגרת המשפטית-רגולטורית
590	1. חקיקה כללית האוסרת על הפליה
592	2. חקיקה או רגולציה כללית המגבילה את השימוש בבינה מלאכותית
595	3. הוראות הרגולטורים הפיננסיים באשר לשימוש במודלים אלגוריתמיים
598	4. חקיקה או רגולציה בנוגע למתן אשראי צרכני
602	ה. הצעות לצמצום הפליה בחיתום אשראי אלגוריתמי
602	1. בקרה פנימית
605	2. התערבות אנושית (human in the loop)
606	3. הסברתיות (explainability)
608	4. פתרונות אלטרנטיביים למודרי אשראי
609	סיכום

מבוא

מאמר זה עוסק באופן שבו מתקבלות החלטות בנוגע להעמדת אשראי צרכני¹ בידים מלווים בנקאיים וחוץ-בנקאיים בישראל, פעולה המכונה בעגה המקצועית "חיתום אשראי". מטרת המאמר היא לבחון אם חיתום אשראי על סמך עיבוד מידע אלגוריתמי עלול לגרום להפליה בתחום האשראי הצרכני ולפגוע באוכלוסיות מוחלשות בישראל. מכיוון שהמודלים לחיתום אינם חשופים לעיון הציבור בהיותם סוד מסחרי של מפתחיהם, בחינתם תהיה תאורטית ברובה ותיעשה על רקע ייחודיותו של משטר השיתוף בנתוני אשראי בישראל, המבוסס מאז חודש אפריל 2019 על קיומו של מאגר לאומי לנתוני אשראי. כמו כן תיבחן הלימותה של הרגולציה (המעטה) הקיימת בישראל בנוגע לשימוש בבינה מלאכותית לצורך

1 המאמר יתמקד באשראי שוטף ליחידים ולמשקי בית. הוא לא יעסוק בהלוואות לדירור.

קבלת החלטות בהשוואה לרגולציה הקיימת באירופה ובארצות הברית, וכן יועלו פתרונות רגולטוריים אפשריים לצמצום החשש להפליה בחיתום אשראי אלגוריתמי.

חיתום אשראי כולל שתי החלטות: ראשית, אם להעמיד אשראי ללקוח, ושנית, מה יהיו תנאי האשראי, לרבות סכומו וגובה הריבית שתיגבה עבורו. חשוב לציין שאין לאדם זכות מוקנית לקבל אשראי, ואין כל חובה על גופים פיננסיים להעמיד אשראי. בכל הנוגע למערכת הבנקאית כך אף נקבע במפורש בחקיקה.² גם בית המשפט העליון חזר על עיקרון זה בפסקי דין רבים.³ העמדת אשראי נתפסת כעסקה מסוכנת מבחינתו של נותן האשראי, שכן מרגע שהוא הלווה את הכסף ללקוח הוא חשוף לסיכון של אי-פירעון החוב, ומכאן נובעת ההסכמה הרחבה שאין לחייב נותני אשראי ליתן אשראי לכל דיכפין. בהתאם, מרכיב מרכזי בחיתום האשראי הוא הערכת הסיכון הטמון במתן האשראי ללקוח ספציפי. הערכה זו מתבססת בעיקרה על שני סוגים של מידע: "מידע חיובי" המעיד על עמידה בהתחייבויות, ו"מידע שלילי" הנוגע לאי-עמידה של הלקוח בהתחייבויותיו. היעדר מידע על אופן עמידת הלקוח בהתחייבויותיו עשוי גם הוא להשפיע באופן שלילי על הערכת סיכון האשראי של הלקוח, כפי שיוסבר בהמשך.⁴

ככל שהערכת סיכון האשראי מבוססת על מסוגלותם הפיננסית של לקוחות לפרוע הלוואות, ויוצרת הבחנה בין לקוחות בעלי כושר פירעון ומוסר תשלומים גבוהים ובין לקוחות בעלי כושר פירעון ומוסר תשלומים נמוכים, מדובר על הבחנה כלכלית מותרת המתחייבת מאופיינו וממהותו של שירות האשראי.⁵ אולם ככל שהערכת סיכון האשראי מבוססת על קריטריונים האסורים על פי חוק דוגמת גזע, מגדר, דת, גיל, מצב משפחתי או מקום מגורים, הרי היא מהווה הפליה אסורה.⁶

בעבר נהגו המלווים השונים להעריך סיכוני אשראי על סמך התרשמות אישית ישירה מהלקוח ומניתוח נתוניו הפיננסיים. אז היה החשש להפליה "מכוונת" – הפליה שמקורה בהעדפות מוטות של המלווים הנובעות מדעות קדומות בנוגע לאוכלוסיות מסוימות, כגון נשים או מיעוטים אתניים. אולם בעקבות מהפכת המידע ופיתוחן של טכנולוגיות ניתוח נתוני עתק מתקדמות, יותר ויותר נותני אשראי מבצעים חיתום אלגוריתמי, לעיתים ללא כל מעורבות אנושית.⁷ המעבר לחיתום אשראי אלגוריתמי מנטרל במידת מה את החשש להפליה מכוונת,⁸ שכן ניתן להגדיר אלגוריתמים כך שלא ישקללו תבחינים אסורים במישרין. עם

2 ס' 2 (א) סיפה לחוק הבנקאות (שירות ללקוח), התשמ"א-1981.

3 ראו למשל ע"א 323/80 אלתיב בע"מ נ' בנק לאומי לישראל בע"מ, פ"ד לו(2) 673 (1983);

ע"א 1507/11 בנק מזרחי טפחות בע"מ נ' אלבס (נבו) 16.1.2014.

4 ראו להלן בפרק ב.2.

5 ראו להלן בפרק ג.1.

6 ס' 3 (א) לחוק איסור הפליה במוצרים, בשירותים ובכניסה למקומות בידור ולמקומות ציבוריים, התשס"א-2000 (להלן: חוק איסור הפליה).

7 Nikita Aggarwal, *The Norms of Algorithmic Credit Scoring*, 80 CAMBRIDGE L.J. 42, 46 (2021).

8 ראו להלן בפרק ג.1.

זאת אלגוריתמים עלולים להוביל להפליה "בלתי־מכוונת", הנגרמת בעקיפין עקב שימוש במידע מוטה לשם פיתוח המודל או בשל האופן שבו המידע הגולמי מעובד.⁹ כיום מלווים שונים מנבאים את סיכון האשראי של הלקוח באמצעות מודלים אלגוריתמיים פנימיים שמשקללים מגוון רחב של נתוני מידע (להלן: מודלים לחיתום אשראי).¹⁰ מידע זה כולל נתוני אשראי (כמו מידע על הלוואות שלא נפרעו), נתונים פיננסיים כלליים (כמו תשלום חשבונות חשמל) ואף נתונים התנהגותיים שאינם פיננסיים (כמו הרגלי קניות או הרגלי גלישה ברשתות החברתיות) (הנתונים שאינם פיננסיים ייקראו להלן: נתונים אלטרנטיביים). מרכיב חשוב במודלים לחיתום אשראי הוא דירוג אשראי שמפיקת לשכות אשראי חיצוניות.¹¹ דירוג אשראי מבוסס על טכניקות סטטיסטיות למיון ולדירוג לקוחות בהתאם לרמת סיכון האשראי שלהם, הנלמד מהיסטוריית האשראי של הלקוח ומנתונים פיננסיים נוספים על אודותיו, בהשוואה לנתונים של לקוחות אחרים בעלי תכונות דומות. המידע מעובד ומנותח באמצעות כלים אלגוריתמיים כדי להשיג תוצאה מספרית המהווה את דירוג האשראי האישי של הלקוח.¹²

לשימוש בכלים אלגוריתמיים בעת חיתום אשראי ישנם יתרונות חשובים ובראשם הגברת יעילות החיתום.¹³ מחקרים מוכיחים, כי דירוג אשראי אלגוריתמי מגביר את יעילות שוקי האשראי הצרכני באמצעות הפחתת העלות והזמן שנדרשים למלווה כדי להשיג את המידע על אודות הלקוח.¹⁴ יתרון נוסף הוא הדיוק: הדירוג מאפשר לנבא ברמת ודאות גבוהה את הסיכון לאי־פירעון ההלוואה בידי הלקוח, ובהתאם לכך לקבל החלטה מיטבית בדבר מתן האשראי ותמחורו.¹⁵ כפועל יוצא הסיכון שמקבל על עצמו המלווה פוחת, ועימו גם

9 ש.ם.

10 Amir E. Khandani, Adlar J. Kim & Andrew W. Lo, *Consumer Credit Risk Models via Machine Learning Algorithms*, 34 J. BANK. & FIN. 2767 (2010). ראו על כך בהרחבה

להלן בפרק ב.3.

11 ראו להלן בפרק א.1.

12 ראו על כך בהרחבה להלן בפרק ב.2.

13 Diederick van Thiel & Willem Frederik van Raaij, *Artificial Intelligence Credit Risk Prediction: An Empirical Study of Analytical Artificial Intelligence Tools for Credit Risk Prediction in a Digital Era*, 12 J. RISK MANAGEMENT IN FIN. INSTITUTIONS 268 (2019).

14 Joseph E. Stiglitz & Andrew Weiss, *Credit Rationing in Markets with Imperfect Information*, 71(3) AM. ECON. REV. 393 (1981); Liran Einav, Mark Jenkins & Jonathan Levin, *The Impact of Credit Scoring on Consumer Lending*, 44 RAND J. ECON. 249 (2013).

15 Julapa Jagtiani & Catherine Lemieux, *The Roles of Alternative Data and Machine Learning in Fintech Lending: Evidence from the Lending Club Consumer Platform* (FRB of Philadelphia Working Paper No. 18-15, 2018), available at <https://ssrn.com/WorldEconomicForum>, abstract=3178461. ראו גם דוח של הפורום הכלכלי העולמי: *The New Physics of Financial Services: Understanding How Artificial Intelligence is Transforming the Financial Ecosystem*, WEF 18 (Aug. 15, 2018), available at <https://www.weforum.org/reports/the-new-physics-of-financial-services-how-artificial-intelligence-is-transforming-the-financial-ecosystem>.

הריבית שמשלם הלקוח. עם זאת הושמעה לא מעט ביקורת כלפי השימוש במנגנוני קבלת החלטות אלגוריתמיים לצורך הערכת אמינותו של מבקש האשראי ומסוגלותו הפיננסית. מחקרים שונים הצביעו על פגיעה הנגרמת ללקוחות עקב שקלול מידע לא-מדויק, עקב מידע מוטעה או עקב שימוש במודלים לא-איכותיים.¹⁶ מחקרים אחרים הצביעו על הפגיעה בפרטיות ועל אובדן האוטונומיה של הלקוח הנגרמת משקלול מגוון רחב של נתוני מידע אישיים על אודותיו.¹⁷

מאמר זה מתמקד בשאלה האם חיתום אשראי על סמך עיבוד מידע אלגוריתמי עלול לגרום להפליה בתחום האשראי הצרכני ולפגוע באוכלוסיות מוחלשות. כמה מחקרים שנערכו בעולם הצביעו על האופן שבו השימוש במודלים אלגוריתמיים לצורך חיתום אשראי עלול להוביל לכך.¹⁸ כך למשל, תועדו השלכות לרעה של השימוש באלגוריתמים על אוכלוסיות מיעוטים,¹⁹ על נשים²⁰ ועל קהילת הלהט"ב.²¹ כמו כן נדונו הסיבות המרכזיות שבגינן עיבוד מידע אלגוריתמי לצורך הערכת סיכון אשראי עלול להוביל להפליה.²² לעומת זאת, ישנם מחקרים שהצביעו דווקא על הרחבת הנגישות לאשראי לקבוצות שסבלו בעבר מהדרת אשראי, וכפועל יוצא על צמצום ההפליה.²³ בישראל טרם נעשתה בחינה שכזו, על אף ייחודיותו של מנגנון דירוג האשראי השורר בה, המבוסס על מאגר נתוני אשראי לאומי.

- Solon Barocas & Andrew D. Selbst, *Big Data's Disparate Impact*, 104 CAL. L. REV. 16 671, 677-93 (2016); Jon Kleinberg et al., *Human Decisions and Machine Predictions*, 133 Q. J. ECON. 237 (2018); Maria Semenova, *Information Sharing in Credit Markets: Incentives for Incorrect Information Reporting*, 50 COMP. ECON. STUD. 381 (2008); Aggarwal, לעיל ה"ש 7, 57.
- Danielle Keats Citron & Frank Pasquale, *The Scored Society: Due Process for Automated Predictions*, 89 WASH. L. REV. 1 (2014) 17
- Talia B. Gillis, *The Input Fallacy*, MINN. L. REV. (forthcoming 2022); Neil Bhutta et al., *How Much Does Racial Bias Affect Mortgage Lending? Evidence from Human and Algorithmic Credit Decisions* (2021), available at https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3887663; Robert Bartlett et al., *Consumer-Lending Discrimination in the FinTech Era*, 143 J. FIN. ECON. 30 (2022) 18
- Andreas Fuster et al., *Predictably Unequal? The Effects of Machine Learning on Credit Markets*, 77(1) J. FIN. 5 (2022) 19
- נמוך יותר להרוויח מהשימוש בלמידת מכונה במסגרת מודלים לחיתום אשראי).
- Finextra, *Generated Credit Scoring Increases Women's Chance of Credit Acceptance*, FINEXTRA (Nov. 12, 2019), available at <https://www.finextra.com/newsarticle/34750/gendered-credit-scoring-increases-womens-chance-of-credit-acceptance> 20
- Cyrus Mostaghim, *Comment, Constructing the Yellow Brick Road: Preventing Discrimination in Financial Services Against the LGBTQ+ Community*, 11 MICH. BUS. & ENTREPRENEURIAL L. REV. 63 (2021) 21
- ראו על כך בהרחבה להלן בפרק 3.ג ו-4. 22
- Michael A. Turner & Robin Varghese, *The Economic Consequences of Consumer Credit Information Sharing: Efficiency, Inclusion, and Privacy* 16-17 (OECD Joint WPISP-WPIE Roundtable, Background Paper No. 2, 2010), available at <https://www.oecd.org/> 23

בחודש אפריל 2019 החל לפעול בבנק ישראל מאגר לאומי של נתוני אשראי, שאליו מוזרמים נתוני אשראי על כלל אזרחי המדינה. לאחר שהמידע המוזרם עובר תהליך "התממה", "תהליך שמטרתו להפוך מידע אישי מוגן לכזה המנותק מכל מאפיין שמזהה את מושאו"²⁴, לשכות האשראי מנתחות את המידע באמצעות מודלים אלגוריתמיים ומספקות למלווים השונים במשק שירותים ומוצרים שונים על בסיסו – המרכזי שבהם הוא דירוג האשראי – המשמשים את המלווים לצורך הערכת סיכון האשראי של לקוחותיהם. החוק אוסר על לשכות האשראי לבסס את המודלים האלגוריתמיים שלהן על תבחינים אסורים, כגון מין, גיל, נטייה מינית, דת, גזע, מצב בריאותי או מצב משפחתי.²⁵ כפי שיוסבר בהרחבה בהמשך, מודלי הדירוג של הלשכות כפופים לתיקוף ולביקורת קפדניים מצד הממונה על נתוני אשראי על מנת לוודא בין היתר כי הם אינם מבוססים על התבחינים האסורים.²⁶ הרושם העולה מכך הוא, כי משטר שיתוף נתוני האשראי שאומץ בישראל אמור לצמצם בצורה ניכרת את החשש להפליה אסורה מצד מלווים כבואם לשקול אם לתת אשראי ללקוח. האומנם? שיחות שערכנו עם מלווים בנקאיים וחוקי-בנקאיים בישראל מלמדות, כי החלטות בנוגע להעמדת אשראי צרכני אינן מבוססות בלעדית על דירוג האשראי המתקבל מלשכות האשראי.²⁷ מלווים שונים פיתחו לעצמם מודלים פנימיים משלהם לחיתום אשראי, המשקללים מידע מסוגים וממקורות שונים על אודות הלקוח מבקש האשראי. כך, לצד דירוג האשראי של הלקוח המגיע מהלשכות כאמור, המודלים הפנימיים מסתמכים על מידע נוסף, כגון מידע פיננסי שמוזרם אליהם במסגרת מערכת הבנקאות הפתוחה,²⁸ וכן על מידע (פיננסי ושאינו פיננסי) שמוסר הלקוח מבקש האשראי. יותר מכך, בהיעדר מגבלות רגולטוריות משמעותיות כאשר לאיסוף מידע פומבי שאינו פיננסי לשם פיתוח מודל חיתום אשראי, מלווים רבים (בעיקר חוקי-בנקאיים) מתבססים גם על נתונים אלטרנטיביים, לרבות נתונים התנהגותיים וחברתיים ופרטי מידע אישיים ממקורות מידע פומביים מגוונים, כגון רשתות חברתיות. המידע האלטרנטיבי משמש הן לשם בניית מודלי דירוג פנימיים לחיתום האשראי והן בעת חיתום אשראי ללקוח ספציפי, כדי לקבל תמונת מצב מקיפה ככל האפשר בעניינו. שלא כמו נתוני האשראי שבמאגר הלאומי, נתוני המידע האלטרנטיביים אינם כפופים לבקרת איכות רגולטורית כלשהי ולכן הם יוצרים סיכון מוגבר להפליה. לאור האמור, המציאות העובדתית, המשפטית והרגולטורית הייחודית לישראל מצדיקה בחינה מקומית של שאלת ההפליה העולה לנבוע מעיבוד מידע אלגוריתמי לצורך חיתום אשראי צרכני.

internet/ieconomy/46968830.pdf; Leon Yehuda Anidjar & Inbar Mizrahi-Borohovich, *Reinventing Credit Data Sharing Regulation*, 29 S. CAL. INTERDISC. L.J. 177, 182 (2020)

24 שרון בר-זיו וטל ז'רסקי "פרטיות במשבר זהות: אסטרטגיות הסדרה בעידן ההתממה" **משפט חברה ותרבות** ב 125, 126 (2019).

25 ראו ס' 51 לחוק איסור אפליה.

26 ראו על כך בהרחבה להלן בפרק א.1.

27 שיחות אלו התקיימו מול מלווים בנקאיים וחוקי-בנקאיים בישראל, דוגמת בנקים, חברות כרטיסי אשראי, פלטפורמות תיווך באשראי (P2P) וגופים פיננסיים חברתיים. על פי בקשת המלווים אנו נמנעות מלציין את שמות הדוכרים שעמם שוחחנו. הפרטים מצויים בידי המחברות.

28 ראו להלן בפרק א.2.

חשש הפליה בעקבות שימוש בבינה מלאכותית וטכניקות מתקדמות של למידת מכונה אינו ייחודי לחיתום אשראי; הוא עלול להתממש גם בתחומים נוספים כגון קבלה לעבודה, השכרת דירות, מתן שירותי ביטוח, טיפולים רפואיים ועוד.²⁹ עם זאת בחרנו למקד את המאמר בחיתום אשראי דווקא לאור ההסדר הייחודי הקיים בתחום זה – מאגר נתוני האשראי הלאומי האמור לשמש בסיס לחיתומי אשראי, והיותו של תחום האשראי תחום מפוקח – מה שמאפשר לאמץ פתרונות הסדרתיים מהירים עד לחקיקת חוק כללי שיסדיר את השימוש בבינה מלאכותית בישראל.

למאמר חמישה פרקים. פרק א יפתח בהצגת משטר השיתוף בנתוני אשראי הקיים כיום בישראל, כרקע לחיתום אשראי אלגוריתמי. משטר השיתוף מבוסס על שני מקורות מידע עיקריים: מאגר נתוני האשראי של בנק ישראל ומערכת הבנקאות הפתוחה. כמו כן תיערך השוואה למשטרי שיתוף הנהוגים בעולם על מנת לעמוד על ייחודיותו של המשטר הישראלי. פרק ב יספק רקע על השימוש בנתוני עתק (ביג דאטה) לצורך הערכת סיכון אשראי, ובהמשך יתמקד במקומם של מודלים אלגוריתמיים בביצוע החיתום. הפרק יציג מודלים לדירוג אשראי ולאחריהם מודלים לחיתום אשראי. חלקו האחרון של פרק זה ימפה את סוגי המידע השונים אשר המלווים משקללים במסגרת מודלים אלגוריתמיים לחיתום אשראי בישראל. פרק ג יעסוק בבעיות ובכשלים המובנים בעיבוד מידע אלגוריתמי, והעלולים להביא לידי הפליה, הדרת אשראי ופגיעה בשכבות המוחלשות. הפרק יתמקד בשתי הבעיות העיקריות: טיב המידע המשמש לבניית המודלים ושיטת עיבוד המידע האמור. לאחר הבנת הבעיות הקיימות בתחום, פרק ד יבחן אם המגבלות החוקיות והרגולטוריות החלות כיום על נתוני האשראי בנוגע לחיתום אשראי אלגוריתמי מעניקות הגנה מספקת ללקוחות מפני החששות האמורים. פרק ה יכלול המלצות אופרטיביות לשינוי הדין הנוהג, במטרה לצמצם תופעות של הפליה ושל הדרה בשוק האשראי הצרכני שעלולות להיגרם ממודל החיתום המיושם בארץ כיום.

א. רקע לחיתום אשראי אלגוריתמי בישראל:

משטר השיתוף בנתוני אשראי

פיתוח מנגנוני קבלת החלטות אלגוריתמיים הוא מאפיין מרכזי של עידן נתוני עתק (big data). המונח "נתוני עתק" מתייחס לכמויות של מידע (volume), מדויק (veracity), מהיר (velocity) ומגוון (variety).³⁰ הודות לטכנולוגיות מחשוב מתקדמות דוגמת טכנולוגיית הענן, כמויות עצומות של מידע גולמי ניתנות כיום לאיסוף, לאחסון ולהפצה. אלגוריתמים משוכללים וטכנולוגיות של למידת מכונה (machine learning) מאפשרים לחפש הקשרים רבים בין פרטי מידע שונים באשר למושא המידע (data mining), לעבד ולנתח נתוני עתק (data analytics) וליצור כלי ניבוי בנוגע לפרט.³¹ כך בכלל וכך בפרט באשר לפיתוח מודלים

29 Nizan Geslevich-Packin, *Disability Discrimination Using Artificial Intelligence Systems and Social Scoring: Can We Disable Digital Bias?*, 8 JICL 1 (2021).

30 JULES J. BERMAN, *PRINCIPLES OF BIG DATA: PREPARING, SHARING AND ANALYZING COMPLEX INFORMATION* 1-2 (2013).

31 מעיין פרל "פרטיות, שליטה ופיקוח בעידן של נתוני עתק: חובת הנמקה על החלטות אלגוריתמיות" *משפט חברה ותרבות* ב 167, 171 (2019).

אלגוריתמיים לחיתום אשראי. נתוני אשראי ונתונים פיננסיים אחרים הם דלק קריטי לפיתוח מודלים אלגוריתמיים לניבוי של סיכון אשראי.³² המסקנה מכך היא שהכרת משטר השיתוף בנתוני אשראי השורר בישראל, אשר מגדיר את היקף הגישה למידע פיננסי על אודות מבקשי אשראי, היא חיונית להבנת הרקע שבעניינו מתפתחים כיום מודלים אלגוריתמיים לחיתום אשראי צרכני.

במציאות הישראלית שוק האשראי למשקי בית הוא שוק ריכוזי הנשלט בידי הבנקים.³³ בעוד שלבנקים יש מידע רב על לקוחותיהם, המאפשר להם לתמחר נכון את הסיכון הכרוך במתן האשראי, מידע זה אינו נמצא בידי המלווים החוץ-בנקאיים,³⁴ אשר נאלצים לתת אשראי בריביות גבוהות מאוד, המשקפות את הסיכון שנובע מחוסר מידע. בעקבות זאת המלווים החוץ-בנקאיים אינם יכולים להתחרות בשוק האשראי הבנקאי. יתרה מזו, היעדר המידע פוגע גם ביכולתם של הבנקים עצמם – בעיקר הבנקים הקטנים – להתחרות על לקוחות בינם לבין עצמם. היעדר המידע גורם לכך שכל אחד מהבנקים הופך למעין מונופול בנוגע ללקוחותיו בשל יתרון המידע שיש לו בעניינם, מצב המעניק יתרון ברור לבנקים הגדולים. מבחינת הלקוחות היעדר התחרות פוגע בלקוחות הטובים, אשר אילו היה המידע עליהם חשוף לנתוני אשראי שונים במערכת, הם היו יכולים לקבל מהם הצעות אשראי בתנאים אטרקטיביים. אולם היעדר תחרות פוגע גם באוכלוסייה המוחלשת, שכן הוא מאפשר להעמיד אשראי בתנאים לא-תחרותיים ובריביות גבוהות, ואף עלול לגרום להדרת אשראי בשל הפחתת מספר המלווים הפעילים בשוק והסיכוי לקבל אשראי ממי מהם. לאור זאת התעורר הצורך בבניית מערך יעיל של שיתוף בנתונים פיננסיים, המגשר על הפער שבין מלווים בעלי מידע ובין מלווים שאין בידיהם מידע, והיוצר תנאים שווים לתחרות בין המלווים.³⁵ זאת ועוד, מחקרים שנערכו לאורך השנים הצביעו על יתרונות רבים נוספים לשיתוף מקיף בנתוני אשראי, כגון אלה: הקצאת אשראי יעילה יותר לאור היכולת לתמחר את

32 אם כי לא הדלק היחיד, שכן גם נתונים אלטרנטיביים, שאינם פיננסיים, עשויים לשמש למטרה זו. ראו להלן בפרק ב.3.

33 הוועדה לבחינת התחרות בשוק האשראי דוח שלישי (16.8.2021) https://www.gov.il/BlobFolder/unit/credit_market_committee/he/Vaadot_ahchud_CreditMarketCommittee_Report_3.pdf; בנק ישראל – מערכת נתוני אשראי "דיווח לוועדת הכלכלה בהתאם לסעיף 113 לחוק נתוני אשראי, התשע"ו-2016" 4-6 (מאי 2021) <https://www.boi.org.il/he/NewsAndPublications/PressReleases/Pages/23-5-21.aspx> (להלן: דיווח לוועדת הכלכלה 2021); בנק ישראל – מערכת נתוני אשראי "דיווח לוועדת הכלכלה בהתאם לסעיף 113 לחוק נתוני אשראי, התשע"ו-2016" 6-7 (אפריל 2022) (להלן: דיווח לוועדת הכלכלה 2022).

34 מלווים חוץ-בנקאיים לצורך מאמר זה הם כל אותם גופים המעניקים אשראי צרכני ואינם בנקים, כגון חברות כרטיסי אשראי, גופים פיננסיים בעלי רישיון למתן אשראי מאת רשות שוק ההון, ביטוח וחיסכון, פלטפורמות לתיווך באשראי (P2P) ואגודות אשראי ופיקדון.

35 הוועדה לשיפור המערכת לשיתוף בנתוני אשראי דוח סופי 29-32 (אוגוסט 2015) <https://economy.pmo.gov.il/CouncilActivity/Finances/Pages/CreditCommittee.aspx>; הצעת חוק נתוני אשראי, התשע"ו-2015, ה"ח 2.

האשראי בצורה מדויקת יותר;³⁶ הרחבת הנגישות לאשראי;³⁷ שיפור מוסר התשלומים של הלווים והקטנת שיעור ההפרות;³⁸ שיפור היציבות הפיננסית של המלווים עקב צמצום במינוף יתר (over-indebtedness);³⁹ וצמצום השיעורים של חדלות פירעון במשק.⁴⁰ על רקע זה נקטה מדינת ישראל לאחרונה שני מהלכים חשובים במטרה ליצור משטר שיתוף בנתונים פיננסיים ולהעמיד לרשות מלווים מידע פיננסי על אודות לקוחות המבקשים אשראי: הקמת מאגר נתוני אשראי בבנק ישראל והקמת מערכת הבנקאות הפתוחה. נדון בכל אחד מאלה בסעיפים הבאים.

1. מאגר נתוני האשראי בבנק ישראל

בחודש אפריל 2019 החל לפעול מאגר נתוני אשראי בבנק ישראל. המאגר הוקם מכוח חוק נתוני אשראי, התשע"ו-2016.⁴¹ סעיף 1 לחוק, המציין את מטרת החוק, מונה בין השאר את המטרות הבאות: הגברת התחרות בשוק האשראי הקמעונאי; הרחבת הנגישות לאשראי; צמצום ההפליה במתן אשראי והפערים הכלכליים.

מכוח החוק הקים בנק ישראל מאגר מידע מרכזי, שאליו מוזרמים באופן שוטף "נתוני אשראי" על כלל אזרחי המדינה. החוק אוסר על מי שאינו בנק ישראל לאסוף, להחזיק או

36 Turner & Varghese, לעיל ה"ש 23, בעמ' 22-24.

37 בעיקר בקרב אוכלוסיות שעובר לקיומו של משטר שיתוף בנתוני אשראי לא יכלו להציג את נתוני האשראי הטובים שלהן, ולכן סורבו בקבלת אשראי. ראו: Turner & Varghese, לעיל ה"ש 23, בעמ' 22-24; Allen N. Berger et al., *Credit Scoring and the Availability, Price, and Risk of Small Business Credit* 9-15, 18-20 (FRB of Atlanta, Working Paper No. 2002-26, 2002), <https://www.atlantafed.org/-/media/documents/research/publications/wp/2002/wp0206.pdf>. סיטואציות אלה אינן באות לגורע מהטענה המרכזית שבמאמר זה

דבר הפליה והדרה בקבלת אשראי בקרב אוכלוסיות מוחלשות, כפי שיוסבר להלן בפרק ג.2.
38 A. Jorge Padilla & Marco Pagano, *Sharing Default Information as a Borrower Discipline Device*, 44 EUR. ECON. REV. 1951, 1954 (2000).

39 Alberto Bennardo, Marco Pagano & Salvatore Piccolo, *Multiple Bank Lending, Creditor Rights, and Information Sharing*, 19 REV. FIN. 519, 523 (2015). Anidjar & Mizrahi-Borohovic, לעיל ה"ש 23, בעמ' 180.

40 ראו Andrew Powell et al., *Improving Credit Information, Bank Regulation and Supervision: On the Role and Design of Public Credit Registries*, (World Bank Policy Research, Working Paper No. 3443, 2004), available at <https://openknowledge.worldbank.org/bitstream/handle/10986/14194/WPS3443.pdf?sequence=1&isAllowed=y>; Turner & Varghese, לעיל ה"ש 23.

41 חוק נתוני אשראי, התשע"ו-2016; קדם לו חוק שירות נתוני אשראי, התשס"ב-2002, שנועד אף הוא להסדיר את העיסוק במכירת מידע פיננסי על אודות אנשים, אך באמצעות מנגנון שונה שלא כלל מאגר נתוני אשראי לאומי. להשוואה בין החוקים, ראו: רות פלאטו-שנער "הזכות לפרטיות פיננסית: עולם הולך ונעלם" *משפט חברה ותרבות* ב 199, 221-226 (2019) (להלן: פלאטו-שנער "הזכות לפרטיות פיננסית"); ענבר מזרחי-בורכוביץ ודוד לוי-פאור "יותר אשראי, יותר מעקב, יותר משטור: עיצוב משטר נתוני האשראי בישראל" *פוליטיקה* 29, 13-18 (2021) https://davis.huji.ac.il/sites/default/files/davisinst/files/mizrachi_levi-faur.pdf

למסור נתוני אשראי על דרך העיסוק, אלא אם מדובר בלשכת אשראי.⁴² "נתוני אשראי" כוללים בין השאר את המידע הבא: נתונים בנוגע להלוואות שהלקוח התחייב לפרוע; צווים או הגבלות שהוטלו על הלקוח לפי דין בשל אי-פירעון; נתונים על בקשות לקוח לקבלת אשראי; נתונים בדבר היקף האשראי שהלקוח רשאי לקבל מנותן אשראי; נתונים בנוגע לסוגי חשבונות אשראי של הלקוח המתנהלים אצל נותן אשראי.⁴³

המידע מוזרם למאגר ממגוון מקורות – בתי המשפט, לשכות ההוצאה לפועל, הממונה על הליכי חדלות פירעון ושיקום כלכלי ובנק ישראל, וכן בנקים, חברות כרטיסי אשראי וגופים פיננסיים גדולים הנותנים אשראי למגזר הצרכני בהיקף שנתי העולה על 250 מיליון שקלים חדשים.⁴⁴ נוסף על מקורות מידע אלה המחויבים על פי החוק במסירת המידע, נטלו על עצמם גם נתוני אשראי קטנים יותר התחייבות למסור מידע, התחייבות שהיא תנאי לקבלת מידע מהמאגר.⁴⁵

המידע הנמסר למאגר הוא רב ומפורט. כך למשל, נמסר מידע על הליכי חדלות פירעון שננקטו נגד הלקוח, הליכי הוצאה לפועל שננקטו נגדו והגבלות שהוטלו עליו מכוח חוק שיקום ללא כיסוי, התשמ"א-1981. הגופים הפיננסיים נדרשים למסור מידע רב ומפורט באשר לאשראי שניתן על ידם ללקוח, ובכלל זה סוג עסקת האשראי, מטרת האשראי, תנאי עסקת האשראי, אופן עמידתו של הלקוח בפירעון העסקה ונתונים בדבר היסטוריית התשלומים במסגרתה. כמו כן נמסר מידע על שיקים שחזרו והוראות תשלום שלא כוכדו.⁴⁶ אף שעיקר הנתונים המפורטים לעיל הם מידע שלילי הנוגע לאי-עמידה של הלקוח בהתחייבויותיו, המידע הנמסר כולל גם מידע חיובי המעיד על יכולת עמידה בהתחייבויות ופירעון הלוואות, כגון הלוואות ותשלומים שנפרעו במועדם.

המידע שבמאגר אמור לשמש את נתוני האשראי במשק. אולם נתוני האשראי אינם רשאים לפנות למאגר המידע ישירות. מסירת המידע מהמאגר נעשית באמצעות מתווכים – לשכות אשראי שקיבלו רישיון שירות נתוני אשראי⁴⁷ וכפופות לפיקוח של הממונה על שיתוף בנתוני אשראי.⁴⁸ בישראל פועלות כיום שתי לשכות אשראי – די.אנ.בי. החברה לנתוני אשראי בע"מ (Dun & Bradstreet) ו-בי. די. אי. קופאס בע"מ (CofaceBDI).⁴⁹ החוק מצמצם את

42 ס' 4 לחוק נתוני אשראי. גוף נוסף המורשה לאסוף, להחזיק או למסור נתוני אשראי הן לשכות מידע על עוסקים, נושא החורג מתחומי מאמר זה המתמקד באשראי צרכני.

43 ראו הגדרת המונח "נתוני אשראי" בס' 2 לחוק נתוני אשראי.

44 ס' 19(א) לחוק נתוני אשראי וס' 3 לכללי נתוני אשראי (הוראות שונות), התשע"ח-2017 (להלן: כללי נתוני אשראי). החוק מונה גם את חברת החשמל כמקור מידע, אולם בהתאם לסמכותו על פי החוק קבע שר המשפטים כי היא תתחיל לדווח רק החל מחודש אפריל 2023. ראו: ס' 19(ג) לחוק, ס' 2 והתוספת הראשונה לתקנות נתוני אשראי, התשע"ח-2017 וצו נתוני אשראי (דחיית יום התחילה לעניין חברת החשמל), התשפ"א-2020.

45 ס' 26(2) לחוק נתוני אשראי; דיווח לוועדת הכלכלה 2021, לעיל ה"ש 33, בעמ' 7.

46 ס' 19(ב) לחוק נתוני אשראי; ס' 2 והתוספת הראשונה לתקנות נתוני אשראי.

47 על פי ס' 7 לחוק נתוני אשראי.

48 שם, בס' 66 לחוק.

49 בנק ישראל – מערכת נתוני אשראי "משתפי המערכת" <https://general.creditdata.org.il/> portal-ashrai-app/corporations-list/CB. להרחבה על דירוגי האשראי של חברות אלו, ראו

היקף הנתונים הנמסרים מהמאגר ללשכות האשראי לנתונים שמועד הכללתם במאגר אינו עולה על שלוש שנים.⁵⁰ תחימת התקופה נועדה בין היתר לאפשר למבקשי האשראי שלא להיות מוכתמים בדירוג אשראי בשל נסיבות חיים מסוימות בתקופה מסוימת. עוד קובע החוק כי לשכות האשראי הן היחידות המוסמכות להפעיל שירות נתוני אשראי, בהתאם לתנאי הרישיון שניתן להן.⁵¹ כדי להגן על פרטיות הלקוחות, לשכות האשראי רשאיות למשוך מידע מהמאגר רק אם וכאשר תוגש להן בקשה מנותן אשראי לקבלת מידע על לקוח מסוים, ובכפוף לקיום התנאים שנקבעו בחוק, לרבות הסכמת הלקוח שעל אודותיו מבוקש המידע.⁵² לשכות האשראי רשאיות לספק לנותני האשראי כמה מוצרים ושירותים, המבוססים אך ורק על המידע שהן מושכות מהמאגר בנוגע ללקוח ספציפי, ובכלל זה דוח אשראי – הכולל את המידע הגולמי הקיים במאגר על אודות הלקוח,⁵³ חיווי דעת בשאלה אם לתת אשראי ללקוח⁵⁴ ודירוג אשראי.⁵⁵ כן רשאיות הלשכות לעסוק בעיסוקים נוספים כגון מכירת מודלים כלכליים, פיתוח כלים לזיהוי הערכה ומדידה של סיכונים, מתן שירותי השוואת עלויות ועוד.⁵⁶ כדי לפתח מודלים סטטיסטיים הדרושים ללשכות האשראי לשם מתן השירותים המתבססים על נתוני האשראי, לשכות האשראי רשאיות לקבל גישה למידע על הלקוחות השונים המצוי במאגר, שמועד הכללתו במאגר חל בחמש השנים שקדמו למועד שבו ניתנה הגישה אליו, במתכונתו המותממת.⁵⁷ החוק אוסר על לשכות האשראי לבסס את המודלים האלגוריתמיים שלהן על תבחינים אסורים כגון מין, גיל, נטייה מינית, דת, גזע, מצב בריאותי או מצב משפחתי.⁵⁸ המידע היחיד שהלשכות רשאיות להשתמש בו לשם בניית מודלי הדירוג שלהן הוא המידע המותמם המצוי במאגר כאמור, ואסור להן להשתמש בכל מידע אחר לשם כך.⁵⁹ לצורך יצירת דירוג ללקוח מסוים, הלשכות מזינות למודל הדירוג שלהן את פריטי המידע המזוהה על אותו לקוח – נתוני האשראי האישיים שלו כפי שהם מופיעים במאגר

להלן בפרק ב.2.

- 50 ס' 47(א) לחוק נתוני אשראי; ראו גם את ס' 23(א) לחוק.
- 51 שם, בס' 5 לחוק.
- 52 ראו את ס' 26(א) ו-27 לחוק. להרחבה לעניין מנגנוני הגנת הפרטיות שנקבעו בחוק, ראו פלאטוֹ-שנער "הזכות לפרטיות פיננסית", לעיל ה"ש 41, בעמ' 226-228.
- 53 ס' 12(א)(1) לחוק נתוני אשראי.
- 54 שם, בס' 12(א)(1) לחוק; ראו גם את ס' 33-36 לחוק.
- 55 שם, בס' 13(א)(1) לחוק.
- 56 שם, בס' 12(ב) לחוק; ס' 2(א) לכללי נתוני אשראי.
- 57 ס' 16(ב)(4) ו-45 לחוק נתוני אשראי. על המאגר הבלתי-מזוהה, ראו: יעל דהרי ונילי דבש-יהלום "המאגר הסטטיסטי על נתוני אשראי למשקי בית" בנק ישראל מבט סטטיסטי 2020 (17.3.2021).
- 58 ס' 51 לחוק נתוני אשראי.
- 59 הוראה 304 של הממונה על שיתוף בנתוני אשראי בבנק ישראל "דירוג אשראי" ס' 20.1 (עדכון מאי 2020) <https://www.creditdata.org.il/media/1226/%D7%94%D7%95%D7%A8%D7%90%D7%94-304-%D7%93%D7%99%D7%A8%D7%95%D7%92-%D7%90%D7%A9%D7%A8%D7%90%D7%99.pdf> (להלן: הוראה מס' 304).

נתוני האשראי⁶⁰ – והתוצאה המספרית שמתקבלת היא דירוג האשראי האישי של הלקוח. יש להעיר כי גישתן של לשכות האשראי לנתוני מידע מזהים בנוגע ללקוח אפשרית רק לצורך מתן שירות נתוני אשראי בנוגע לאותו לקוח, על סמך בקשה ספציפית שהגיש נותן האשראי ללשכת האשראי ובכפוף להסכמת הלקוח.⁶¹ הלשכות אינן רשאיות להשתמש במידע אלטרנטיבי, בין אם לשם בניית מודל הדירוג ובין אם בעת עריכת דירוג אישי ללקוח. לשכות האשראי כפופות לפיקוח של הממונה על השיתוף בנתוני אשראי בבנק ישראל.⁶² אחד מתפקידי הממונה הוא מתן הוראות ללשכות האשראי בנוגע לדרכי פעילותן. מכוח סמכות זו פרסם הממונה הוראה המפרטת את הדרישות השונות בנוגע לפיתוח מודלי הדירוג של הלשכות.⁶³ תפקיד נוסף של הממונה הוא "פיקוח ועריכת בקרה על פעולתן של לשכות האשראי... ובכלל זה לגבי פיתוח המודלים הסטטיסטיים בידי הלשכות".⁶⁴ החוק מקנה לממונה ולמפקחים מטעמו סמכויות נרחבות, הכוללות דרישה לקבלת כל מידע, מסמך או עותק של חומר מחשב מכל אדם, סמכות לחדור לחומר מחשב של לשכת אשראי וסמכות להיכנס לכל מקום שבו פועלת לשכת אשראי.⁶⁵ המפקחים רשאים להסתייע במומחים לשם ביצוע תפקידם.⁶⁶

משטר של שיתוף בנתוני אשראי אינו המצאה ישראלית; הוא החל לפעול בארצות הברית עוד במאה התשע-עשרה. עם התפתחות האמצעים הטכנולוגיים והתרחבותן של מערכות האשראי הפך התחום לתעשייה של ממש, שבמסגרתה נוצר שוק מידע פיננסי והתפתחה מסגרת ממוסדת של איסוף, של דירוג ושל סחר במידע פיננסי על אנשים.⁶⁷

60 ס' 13(א) לחוק נתוני אשראי.

61 שם, בס' 26 ו-27 לחוק.

62 שם, בס' 66 לחוק.

63 הוראה מס' 304, לעיל ה"ש 59.

64 סעיף 66(ב)(2) לחוק נתוני אשראי.

65 שם, בס' 85-86 לחוק, כפוף למגבלות המפורטות באותם סעיפים.

66 שם, בס' 87 לחוק.

67 Robert M. Hunt, *A Century of*; 177 בעמ' 23, לעיל ה"ש 23, Anidjar & Mizrahi-Borohovich *Consumer Credit Reporting in America* (Federal Res. Bank of Philadelphia, Working Paper No. 05-13, 2005), available at <https://www.philadelphiafed.org/-/media/frbp/assets/working-papers/2005/wp05-13.pdf?la=en&hash=FCFC0842F9EC8E7272AF17763E169964>. גם במרבית מדינות אירופה משטר השיתוף בנתוני אשראי מבוסס על לשכות אשראי פרטיות, האוספות את המידע במישרין ממקורות המידע השונים והמספקות שירותים שונים – לרבות דירוגי אשראי – על בסיסו. ראו: Federico Ferretti, *The Never-Ending European Credit Data Mess*, EUROPEAN CONSUMER ORGANISATION (BEUC) 1, 13 (2017), available at https://www.beuc.eu/publications/beuc-x-2017-111_the-never-ending-Federico-F-Ferretti. european-credit-data-mess.pdf. לסקירת השיטה בכריטניה, ראו: Federico F. Ferretti, *Re-Thinking the Regulatory Environment of Credit Reporting: Could Legislation Stem Privacy and Discrimination Concerns?*, 14 J. FIN. REG. & COMP. 254, 255 (2006) לסקירת מודלים במדינות נוספות, ראו: CREDIT REPORTING SYSTEMS AND THE INTERNATIONAL ECONOMY (Margaret J. Miller ed., 2003).

השיטה האמריקנית לשיתוף בנתוני אשראי שונה מהשיטה הישראלית. בארצות הברית אין מאגר מידע לאומי, והשיטה מבוססת על לשכות אשראי כגורם המרכזי שמנהל ומתפעל את משטר השיתוף. לשכות האשראי מקבלות את המידע ישירות ממקורות המידע, ועורכות אותו בצורה של דוחות אשראי שאותם הן מוכרות לקונים שונים המורשים לקבלם על פי החוק.⁶⁸ ישנן שלוש לשכות אשראי מרכזיות השולטות על מרבית השוק.⁶⁹ נוסף להן פועלות עוד מאות לשכות קטנות.⁷⁰ לשכות אשראי הן הגורם הבלעדי המוסמך לנפק דוחות אשראי.⁷¹ הלשכות אינן זקוקות לרישיון לצורך פעילותן.⁷² עם זאת הן כפופות לחוק שמטרתו להבטיח שהן פועלות בהגינות, ללא משוא פנים, תוך שמירה על הזכות לפרטיות של הלקוחות והנפקת דוחות אשראי מדויקים ואמינים.⁷³ מאז שנת 2012 הלשכות כפופות לפיקוח של הרגולטור הפיננסי הצרכני, ה־Consumer Financial Protection Bureau.⁷⁴

השיטה האמריקנית מאפשרת לאסוף מידע רחב מאוד על הלקוח משורה ארוכה של מקורות מידע. המידע כולל הן מידע שלילי המעיד על אי־עמידה בהתחייבויות והן מידע חיובי המעיד על עמידה בהן. מקורות המידע העיקריים הם אלה: בנקים, חברות כרטיסי אשראי ומלווים שונים, המוסרים מידע פיננסי; רשויות ציבוריות, שמהן נאסף מידע על פשיטות רגל, על עיקולים, על שעבודים, ועל פסקי דין אזרחיים; וגורמים מסחריים כגון חברות המספקות חשמל, מים וגז, חברות תקשורת, חברות ביטוח, משכירי נכסים ורשתות קמעונאיות גדולות, שמהם מתקבל מידע על היסטוריית תשלומי הצריכה של הלקוח, על תביעות ביטוח, על תשלומי שכירות ועוד.⁷⁵ נוסף לכל אלה נאספים גם נתוני מידע אישיים כגון מידע רפואי, היסטוריית מגורים, השכלה והיסטוריה תעסוקתית.⁷⁶

Robert B. Avery, Paul S. Calem & Glenn B. Canner, *An Overview of Consumer Data and Credit Reporting*, 89 FED. RES. BULLETIN 47 (2000), available at <https://www.federalreserve.gov/pubs/bulletin/2003/0203lead.pdf> 68

Equifax Information Services LLC, TransUnion LLC, Experian: לשכות האשראי הן אלה: Consumer Financial Protection Bureau, *Key Dimensions*: ראו: Information Solutions Inc. *and Processes in the U.S. Credit Reporting System: A Review of How the Nation's Largest Credit Bureaus Manage Consumer Data 2* (2012), available at https://files.consumerfinance.gov/f/201212_cfpb_credit-reporting-white-paper.pdf (להלן: CFPB) 69
(Key Dimensions)

Consumer Financial Protection Bureau, *CFPB to Supervise Credit Reporting* (Press Release, Jul. 16, 2012), available at <https://www.consumerfinance.gov/about-us/newsroom/consumer-financial-protection-bureau-to-supervise-credit-reporting-2> (להלן: CFPB Press Release) 70

.Fair Credit Reporting Act, 15 U.S.C. § 1681b(a) 71

ראו את הגדרת המונח "consumer reporting agency" שם, בס' 1681a(f). 72

שם, בס' 1681(a). 73

CFPB Press Release, לעיל ה"ש 70. 74

על חשיבותו של מידע נוסף זה, ראו Turner & Varghese, לעיל ה"ש 23. 75

Avery, Calem & Canner, לעיל ה"ש 68, בעמ' 47; *CFPB Key Dimensions*, לעיל ה"ש 69, בעמ' 8-9, 14. 76

מסירת המידע בידי מקורות המידע היא וולונטרית; אין שום חוק המחייבם לעשות זאת. מקורות המידע משתפים פעולה בשל הבנתם את חשיבות הנושא וכאמצעי להרתיע לקוחות מפני אי-תשלום.⁷⁷ בפועל מועבר מידע שוטף על מיליארדים של חשבונות לאחת או יותר מלשכות האשראי הפעילות במדינה.⁷⁸ כל המידע שנאסף נכלל בדוחות האשראי שלשכות האשראי עורכות ומוכרות. הדוח כולל בדרך כלל מידע שנאסף במשך שבע השנים האחרונות, אולם נתונים מסוימים כמו נתוני פשיטת רגל יכולים להישמר במשך עשר שנים.⁷⁹ הדוח גם כולל פרטים על בקשות שהוגשו לקבלת מידע מתיק המידע שקיים בלשכה על אודות הלקוח.⁸⁰ מלבד מכירת דוחות אשראי על לקוחות, שירות מרכזי נוסף שלשכות האשראי האמריקניות מספקות הוא דירוג אשראי של לקוחות. מודל הדירוג השכיח שבו משתמשות לשכות האשראי האמריקניות הוא המודל הגנרי של חברת FICO.⁸¹ בשנת 2006 הקימו שלוש לשכות האשראי הגדולות מיזם משותף בשם "VantageScore", המציע מודלי דירוג מתחרים.⁸² בפועל כל לשכת אשראי מתבססת על מודלי דירוג משלה. עניין זה, בצירוף העובדה שהמידע המוזרם לכל אחת מהלשכות אינו בהכרח זהה, מובילים לא אחת להבדלים בדירוגי הלשכות השונות הניתנים לאותם לקוחות.⁸³ בכך שונה השיטה הישראלית, שבה דירוגי הלשכות מבוססים על מידע זהה – המידע המותמם שבמאגר – ולכן ההבדלים בין הדירוגים זניחים. ההבדל בין הדירוגים עשוי לסייע ללקוחות בעלי דירוג נמוך, שכן הוא עשוי להגדיל את הסיכוי שלהם להשיג דירוג טוב יותר מלשכה אחרת שיאפשר להם לקבל אשראי. מנגד, ההבדל בדירוגים

77 שם, בעמ' 15.

78 Consumer Financial Protection Bureau, *Quarterly Consumer Credit Trends – Payment Amount Furnishing & Consumer Reporting* (Nov. 2020), available at https://files.consumerfinance.gov/f/documents/cfpb_quarterly-consumer-credit-trends_report_2020-11.pdf

79 Consumer Financial Protection Bureau, *How Long Does Negative Information Remain on My Credit Report?*, available at <https://www.consumerfinance.gov/ask-cfpb/how-long-does-negative-information-remain-on-my-credit-report-en-323>

80 Avery, Calem & Canner, לעיל ה"ש 68, בעמ' 48.

81 להרחבה בנושא דירוג זה, ראו להלן בפרק ב.2.

82 ראו באתר חברת VantageScore בכתובת: <https://vantagescore.com>.

83 Consumer Financial Protection Bureau, *What Is a Credit Score?* CFPB (Sep. 1, 2020), <https://www.consumerfinance.gov/ask-cfpb/what-is-a-credit-score-en-315/>; Nizan Geslevich Packin & Yafit Lev-Aretz, *On Social Credit and the Right to Be Unnetworked*, COLUM. BUS. L. REV. 340, 351 (2016). בדיקה של הרגולטור הפיננסי הצרכני העלתה, שבנוגע ללקוחות בעלי דירוג נמוך ישנם לעיתים הבדלים גם בין הדירוגים שנמכרים לצרכנים לבין הדירוגים הנמכרים למלווים. ראו: Consumer Financial Protection Bureau, *Analysis of Differences Between Consumer- and Creditor- Purchase Credit Scores* (September 2012), available at https://files.consumerfinance.gov/f/201209_Analysis_Differences_Consumer_Credit.pdf

פוגע בוודאות המסחרית של נותני האשראי, משום שהם אינם יכולים לדעת בוודאות אם הדירוג שעליו הם מסתמכים הוא המציג את התמונה המדויקת ביותר של הלקוח.

2. מערכת הבנקאות הפתוחה

מערכת הבנקאות הפתוחה נועדה להגדיל את התחרות בתחום הפיננסי, לרבות בתחום האשראי. במסגרת מערכת זו נדרשים הגופים הפיננסיים לפתוח את המידע הקיים בידיהם על לקוחותיהם בפני צדדים שלישיים המספקים שירותי מידע פיננסי (כגון חברות פינטק שקיבלו רישיון מיוחד לכך),⁸⁴ בכפוף להסכמת הלקוח. על בסיס מידע זה יוכלו נותני שירותי המידע הפיננסי להציע ללקוח שירותים כמו ריכוז כלל המידע הפיננסי שלו במקום אחד, השוואת עלויות בין גופים פיננסיים שונים, העברת מידע לגופים פיננסיים במטרה לקבל הצעות ערך מתחרות עבור הלקוח וכן ייעוץ פיננסי, הכול באופן דיגיטלי ומתקדם. המידע מועבר באמצעות ממשק טכנולוגי אחיד שכל המשתמשים במערכת נדרשים להתחבר אליו (Application Programming Interface – API). מבחינת נותני האשראי במשק יש למערכת הבנקאות הפתוחה חשיבות רבה, שכן היא מעניקה להם גישה למידע חשוב שאינו נכלל כיום במאגר המידע של בנק ישראל, ומאפשרת להם להעריך בצורה טובה ויעילה יותר את הסיכונים ואת הסיכויים של מתן אשראי לכל לקוח.⁸⁵

בחודש נובמבר 2021 נחקק חוק שירות מידע פיננסי, התשפ"ב-2021,⁸⁶ המסדיר את מערכת הבנקאות הפתוחה בישראל. החוק מחייב גופים פיננסיים שונים המחזיקים במידע פיננסי על לקוחות (מקורות מידע) לאפשר גישה מקוונת למידע זה לחברות שיקבלו רישיון או אישור למתן שירותי מידע פיננסי ("נותני שירות מידע פיננסי"),⁸⁷ בכפוף להסכמת הלקוח.⁸⁸ גם לשכות אשראי יהיו רשאיות לפעול כנותני שירות מידע פיננסי, בכפוף לקבלת אישור מהממונה על השיתוף בנתוני אשראי בבנק ישראל.⁸⁹

החוק אוסר על נתן שירות מידע פיננסי לאסוף מידע פיננסי, לקבלו מאחר או להשתמש בו אלא לשם מתן השירות ללקוח ובכפוף להסכמת הלקוח.⁹⁰ עם זאת החוק קובע, כי נתן שירות ראשי להשתמש במידע פיננסי שאסף או שקיבל מאחר גם למטרות סטטיסטיות הקשורות למתן שירות מידע פיננסי לכלל לקוחותיו, ובלבד שניתנה לכך הסכמה מפורשת

84 במאמר זה המונח "חברות פינטק" מתייחס לחברות שמשמשות בטכנולוגיה חדשה לצורך אספקת מוצרים ושירותים פיננסיים. לשימוש במונח זה, ראו למשל: צוות בין-משרדי לבחינת הקמתה של סביבת ניסוי לחברות טכנולוגיה פיננסיות דוח סופי (ינואר 2019). https://www.gov.il/he/departments/news/press_24022019.

85 הצעת חוק התוכנית הכלכלית (תיקוני חקיקה ליישום המדיניות הכלכלית לשנות התקציב 2021 ו-2022), התשפ"א-2021, ה"ח 840, 1008, 1009 (להלן: הצעת חוק התוכנית הכלכלית).

86 חוק שירות מידע פיננסי, התשפ"ב-2021, ס"ח 288. החוק ייכנס לתוקף בצורה מדורגת, ראו את ס' 79 לחוק.

87 שם, בס' 2 לחוק.

88 שם, בס' 39, 40, ו-42 לחוק.

89 שם, בס' 2(ב) ו-13 לחוק.

90 שם, בס' 25(א)-(ג) לחוק.

של הלקוח בכתב, ושהמידע שיוצג ללקוחות יהיה מידע סטטיסטי מצרפי אשר אינו מזוהה.⁹¹ בהצעת החוק מוסבר, כי המידע הרב שיהיה בידי נותן שירותי התשלום יוכל לשמש אותו כדי לפתח מודלים סטטיסטיים לשם שיפור השירות ללקוחות.⁹² החוק אינו אוסר במפורש על נותני שירותי מידע להשתמש במידע לשם בניית מודלים לדירוג אשראי, אולם על סמך הדוגמאות המובאות בהצעת החוק⁹³ נראה כי לא לכך התכוון המחוקק.

החוק קובע מגבלות בנוגע לשימוש במידע גם באשר לגופים הפיננסיים שיקבלו את המידע מאת נותני שירותי המידע. בין השאר החוק אוסר עליהם להשתמש במידע שלא לצורך המטרה שלשמה הוא נמסר להם, היינו לצורך הגשת הצעת התקשרות ללקוח.⁹⁴ בהתאם לכך עליהם למחוק את המידע בתום השימוש בו ולא יאוחר מ-30 ימים מיום קבלתו, אלא אם כן הם התקשרו עם הלקוח שבעניינו ניתנה הצעת ההתקשרות.⁹⁵ עולה מכך, כי גם הגופים הפיננסיים אינם רשאים להשתמש במידע שהתקבל במסגרת מערכת הבנקאות הפתוחה לשם פיתוח מודלי דירוג אשראי משלהם.

שיטת הבנקאות הפתוחה פועלת במדינות רבות במודלים שונים, ובראשן ארצות הברית.⁹⁶ בארצות הברית אין הסדרה ייעודית של התחום, בהתבסס על גישה המעדיפה להשאיר את פיתוחו לכוחות השוק. בעקבות זאת אין הגבלות או סטנדרטים אתיים מקובלים בנוגע לאופן איסוף המידע והשימוש בו, כגון איסור על שימוש סטטיסטי בנתונים לצורך בניית מודלים.⁹⁷ גישה אחרת נהוגה בשוק האירופי, שם ישנה הסדרה מפורטת בדירקטיבה בנושא שירותי תשלום (Payment Services in the Internal Market Directive (PSD2)).⁹⁸ עם זאת הדירקטיבה אינה מטילה הגבלות על שימוש במידע לצרכים סטטיסטיים של נותני השירות.

-
- 91 שם, בס' 25(ד)(2) לחוק.
- 92 הצעת חוק התוכנית הכלכלית, לעיל ה"ש 85, בעמ' 1038.
- 93 כגון מודל סטטיסטי שבאמצעותו יהיה אפשר לבחון כיצד ניתן לשפר את מצבו של הלקוח, או מודל שבאמצעותו נותן השירות יוכל להתריע בפני לקוחות כשהוצאותיהם על שירות מסוים גבוהות לעומת הוצאות של לקוחות בעלי מאפיינים דומים. ראו שם.
- 94 ס' 29(א), 29(ג)(2) ו-29(ה) לחוק שירותי מידע פיננסי, התשפ"ג-2021.
- 95 שם, בס' 29(ג)(4) לחוק.
- 96 Deloitte, *Open Banking Around the World – Towards a Cross-Industry Data Sharing Ecosystem*, DELOITTE (Accessed Jul. 20, 2022), available at <https://www2.deloitte.com/global/en/pages/financial-services/articles/open-banking-around-the-world.html>; Oscar Borgogno & Giuseppe Colangelo, *Regulating FinTech: From Legal Marketing to the Pro-Competitive Paradigm*, 13-15 (2020), available at https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3563447.
- 97 Nizan Geslevich Packin, *Show Me the (Data About the) Money!*, 2020(5) UTAH L. REV. 1277.
- 98 EC, Directive 2015/2366/EU of the European Parliament and of the Council of 25 November 2015 on Payment Services in the Internal Market, amending Directives 2002/65/EC, 2009/110/EC and 2013/36/EU and Regulation (EU) No 1093/2010, and repealing Directive 2007/64/EC, O.J. L. 337, <https://eur-lex.europa.eu/legal-content/EN/TXT/PDF/?uri=CELEX:32015L2366&from=EN>

לסיכום, שתי השיטות האמורות – מאגר נתוני האשראי ומערכת הבנקאות הפתוחה – אמורות לתת לנתוני האשראי מידע פיננסי חשוב על אודות הלקוח מבקש האשראי ולשמש מרכיב מרכזי בחיתום האשראי עבורו. כפי שנראה בפרק הבא, מידע פיננסי זה משוקלל בידי נתוני האשראי יחד עם מידע נוסף לשם פיתוח מודלים אלגוריתמיים לחיתום אשראי צרכני.

ב. קבלת החלטות בנוגע להעמדת אשראי צרכני: מקומם של מודלים אלגוריתמיים

1. ניתוח אלגוריתמי של נתוני עתק לצורך הערכת סיכון אשראי

מדע הנתונים (data science) הולך ותופס מקום מרכזי במחקר האקדמי והמעשי, בעולם בכלל ובישראל בפרט.⁹⁹ מדע הנתונים משמש בין היתר לפיתוח מודלים אלגוריתמיים שמסוגלים ליצור ניבויים סטטיסטיים שונים, המשמשים הן את התעשייה הפרטית והן את המגזר הציבורי. הדלק המרכזי המניע פיתוחים אלו הוא המידע האישי הרב על אודות הפרט המצוי במרשתת ובמאגרי מידע שונים, והזמין לאיסוף ולניתוח באמצעים אלגוריתמיים. מבחינה סוציולוגית הפכנו לחברה מרושתת (networked society), שבה חלק ניכר מהפעילות היומיומית שלנו מתבצע "אונליין".¹⁰⁰ אנחנו קונים ומוכרים באמצעות פלטפורמות אינטרנטיות דוגמת אמזון (Amazon) ועלי אקספרס (Ali Express); אנחנו מנהלים קשרים חברתיים דרך רשתות חברתיות דוגמת פייסבוק (Facebook), אינסטגרם (Instagram) וטוויטר (Twitter); אנחנו בונים קריירות באמצעות פלטפורמות דוגמת לינקד-אין (LinkedIn); ואנחנו מנהלים את חשבון הבנק שלנו באמצעות שירותים דיגיטליים. שימושים יומיומיים אלו בפלטפורמות, באתרי אינטרנט, ברשתות חברתיות ובמנועי חיפוש משאירים אחריהם "עקבות דיגיטליים" – שובל של מידע אישי על הפרט, על העדפותיו, על רצונותיו, על תחומי העניין שלו ועל מאפייניו.¹⁰¹ מדובר בכמויות מידע עצומות ומגוונות שזכו לכינוי "נתוני עתק" (big data), והן הוזהב החדש של ענקיות הטכנולוגיה שמתחרות על איסוף המידע וניתוחו.¹⁰² היכולת המתקדמת לאסוף, לשמור, לעבד ולנתח נתוני עתק באמצעות טכנולוגיות חדישות המבוססות על בינה מלאכותית (Artificial Intelligence (AI)), דוגמת למידת מכונה (Machine Learning (ML)), טומנת בחובה הזדמנויות ואפשרויות בלתי-רגילות להתייעלות המשק,

99 אושרית גן-אל "האוניברסיטאות כבר ערוכות: זהו המקצוע החדש והמבוקש במשק" גלובס <https://www.globes.co.il/news/article.aspx?did=1001274089> (24.2.2019) ("מדעי הנתונים הפכו בשנים האחרונות לתחום רב השפעה בעולם ההייטק ובמחקר האקדמי. היכולת להתמודד עם נתוני ענק מצריכה כישורים במתמטיקה, בסטטיסטיקה ובמחשבים, ועל כן אנו רואים חשיבות רבה בהכשרתם של כמה שיותר בוגרים בתחום").

100 VIKTOR MAYER-SCHÖNBERGER & KENNETH CUKIER, BIG DATA: A REVOLUTION THAT WILL TRANSFORM HOW WE LIVE WORK AND THINK 73 (2013).

101 מיכאל בירנהק מרחב פרטי: הזכות לפרטיות בין משפט לטכנולוגיה 169 (2010).

102 Itay Levy, *If Data Is The New Oil, Tech Leaders Should Consider "Green" Alternatives*, FORBES (May 25, 2021), <https://www.forbes.com/sites/forbestechcouncil/2021/05/25/if-data-is-the-new-oil-tech-leaders-should-consider-green-alternatives>

לשיפור איכות השירותים הניתנים ולהתאמתם לצורכי הפרט (personalized consumption). למעשה, עיבוד וניתוח נתוני עתק מאפשר למקבלי החלטות שונים להשתמש במנגנוני קבלת החלטות אלגוריתמיים (Algorithmic Decision Making), במקום או לצד המנגנונים האנושיים המסורתיים. כך למשל, רשויות אכיפה נעזרות בניבויים סטטיסטיים שנוצרו מאיסוף, מהצלבה ומעיבוד אלגוריתמיים של מידע אישי כדי להעריך מסוכנות פוטנציאלית של עבריינים.¹⁰³ שימושים דומים במנגנוני ניבוי אלגוריתמיים הם לצורך הערכת פוטנציאל של מועמדים בשוק דורשי העבודה¹⁰⁴ או לשם ניבוי רמת הביצוע של סטודנטים במסודות להשכלה גבוהה.¹⁰⁵ לכאורה, לצד יעילות השימוש במנגנוני קבלת החלטות אלגוריתמיים, מנגנונים אלו אמורים (בכפוף לעיצוב ראוי ופיקוח מוקדם) לנטרל ניגודי עניינים ומשוא פנים ולאפשר קבלת החלטות עקבית, אחידה, אובייקטיבית ושוויונית.¹⁰⁶

אחד התחומים שבהם ניכר השימוש במנגנוני קבלת החלטות אלגוריתמיים הוא תחום האשראי הצרכני.¹⁰⁷ בפרט, מלווים שונים נעזרים במודלים אלגוריתמיים כדי להעריך את אמינותו של מבקש האשראי ואת מסוגלותו לעמוד בהתחייבויות כספיות, כפי שיוסבר להלן.¹⁰⁸ אם בעבר נותני אשראי היו מבססים את הערכת אמינותו ועמידתו של מבקש אשראי בהתחייבויות על סמך התרשמות אישית וניסיון אנושי, הרי כיום הערכות אלו נשענות בחלקן על מודלים אלגוריתמיים.¹⁰⁹ מודלים אלו מתרגמים את סיכון האשראי של הלקוח לנתון מספרי, המהווה את דירוג האשראי האישי שלו;¹¹⁰ הם עושים זאת באמצעות טכניקות סטטיסטיות למיון ולדירוג לקוחות בהתאם לסיכון האשראי שלהם, הנלמד מהיסטוריית האשראי של הלקוח ומנתוני אשראי של לקוחות אחרים בעלי תכונות דומות.¹¹¹ נרחיב על כך להלן.

-
- Andrew Guthrie Ferguson, *Predictive Policing and Reasonable Suspicion*, 62 EMORY L.J. 259, 265-69 (2013) 103
- ראו למשל Explorium, *Conceptualizing a Model To Predict Successful Hires: Reframing the Problem*, EXPLORIUM (Sep. 24, 2020), <https://www.explorium.ai/blog/conceptualizing-a-model-to-predict-successful-hires-reframing-the-problem/> 104
- Wanli Xing, *Exploring the Influences of Mooc Design Features on Student Performance and Persistence*, 40 DISTANCE EDUCATION 98 (2019) 105
- פרל, לעיל ה"ש 31. 106
- Mikella Hurley & Julius Adebayo, *Credit Scoring in the Era of Big Data*, 18 YALE J.L. & TECH. 148 (2016) 107
- ראו למשל Khandani, Kim & Lo, לעיל ה"ש 10. 108
- Aggarwal, לעיל ה"ש 7, בעמ' 46. 109
- Hussein A. Abdou & John Pointon, *Credit Scoring, Statistical Techniques and Evaluation Criteria: A Review of the Literature*, 18 INTELLIGENT SYSTEMS ACCT. FIN. & MGMT. 59, 62 (2011) 110
- שם. 111

2. מודלים לדירוג אשראי

דירוג אשראי נעשה באמצעות מודל סטטיסטי, המסוגל להעריך את היכולת של לקוחות לעמוד בהתחייבויותיהם ולפרוע את חובותיהם בזמן.¹¹² המודל משמש לחישוב דירוג אשראי פרטני עבור כל לקוח ולהערכת ההסתברות שאותו לקוח יוכל לעמוד בהתחייבויותיו. ככל שמוסר התשלומים של הלקוח גבוה יותר, כך גם דירוג האשראי שלו גבוה יותר, ללא קשר לנתונים אחרים כגון רמת ההכנסה שלו. ככלל, דירוג אשראי גבוה יותר יאפשר ללקוח לקבל אשראי בתנאים טובים יותר.¹¹³

השיטה הבסיסית לפיתוח מודל לדירוג אשראי מבוססת על ניתוח נתוני אשראי היסטוריים ועל חיפוש מתאם (קורלציה) בין הנתונים לבין כשל אשראי – מקרים שבהם לקוחות לא החזירו הלוואות בזמן. כלומר, המטרה היא לאתר נתוני מידע המשותפים ללקוחות שנכשלו בהחזרת הלוואותיהם בזמן על מנת לפתח יכולת לנבא כשל אשראי בעתיד.¹¹⁴

נתוני האשראי ההיסטוריים שעליהם מסתמכות לשכות האשראי בישראל הם נתוני האשראי המצויים במאגר המידע בבנק ישראל. אחת ממטרות המאגר היא "יצירת בסיס מידע לא מזוהה שישמש את לשכות האשראי לשם פיתוח מודלים סטטיסטיים",¹¹⁵ לרבות מודלים לדירוג אשראי.¹¹⁶ בהתאם, בנק ישראל הוסמך לתת ללשכות האשראי גישה לנתוני המידע שבמאגר לצורך פיתוח מודלים סטטיסטיים, כשהם מותממים.¹¹⁷ לשכות האשראי מעבדות את נתוני האשראי המותממים שבמאגר לאלגוריתם (נוסחה) שמשקלל את ההשפעה של כל נתון על סיכון האשראי לפי הממצאים, ומהווה את הבסיס למודל הדירוג שלהן.¹¹⁸ ככלל, המודלים האלגוריתמיים שבאמצעותם מפיקות לשכות האשראי את דירוגי האשראי שלהן אינם חשופים בהיותם סוד מסחרי מוגן.¹¹⁹ אולם ניתן לציין כי הם אינם זהים, ולכן ישנה שונות בין הדירוגים השונים שמפיקות הלשכות השונות.¹²⁰ כך למשל, בישראל חברת CofaceBDI משתמשת במודל הדירוג של החברה הבינלאומית FICO. הדירוג נע בטווח הציונים 300-850, וציון של 660 ומעלה נחשב לדירוג טוב.¹²¹ לעומת זאת, המודל של Dun & Bradstreet פותח על ידה יחד עם חברת G-Stat, טווח הציונים שלו נע בין 0 ל-1000,

112 ראו את אתר "מערכת נתוני אשראי" של בנק ישראל בכתובת: <https://www.creditdata.org.il>

113 דיווח לוועדת הכלכלה 2021, לעיל ה"ש 33, בעמ' 19.

114 שם.

115 ראו את ס' 16(ב)(4) לחוק נתוני אשראי.

116 שם.

117 ראו את ס' 45 לחוק נתוני אשראי.

118 על מגבלות ההתממה, ראו בר-זיו וז'רסקי, לעיל ה"ש 24, בה"ש 78.

119 Geslevich Packin & Lev-Aretz, לעיל ה"ש 83, בעמ' 355.

120 ראו *How Are Credit Scores Calculated*, EQUIFAX, <https://www.equifax.com/personal/education/credit/score/how-is-credit-score-calculated/>

121 ראו "דירוג FICO®BDI" <https://personalcheck.bdi.co.il/Web/Home/> CofaceBDI .CreditRating

וציון של 661 ומעלה נחשב לדירוג טוב.¹²² ככלל, אין רשימה ממצה של נסיבות שיכולות לגרום להורדת הדירוג, משום שיש שונות גדולה בין הלקוחות המבוססת על מכלול הנתונים הקיימים בעניינם.¹²³ עם זאת מאחר שלשכות האשראי בישראל מפתחות את המודלים שלהן על סמך אותו בסיס נתונים – מאגר נתוני האשראי של בנק ישראל – נראה כי השונות בין הדירוגים שלהן צפויה להיות זניחה.¹²⁴ לעומת זאת, כאשר בסיס הנתונים המשמש לפיתוח מודל הדירוג אינו זהה, ניתן לצפות לסטיות משמעותיות יותר בין הדירוגים השונים. זהו המצב בארצות הברית, למשל, שם לא כל המלווים בשוק מדווחים בצורה אחידה לכל לשכות האשראי.¹²⁵

המודלים המסורתיים אשר בבסיס דירוגי האשראי שמפיקות לשכות אשראי משקללים נתוני מידע פיננסי בלבד.¹²⁶ כך, דירוג האשראי של FICO מבוסס על חמישה קריטריונים, שכל אחד מהם מורכב מכמה משתנים בעלי משקל שונה: (1) היסטוריית האשראי של הלקוח מהווה 35% ממשקל הדירוג. בקריטריון זה נכללים נתונים על אודות איחורים בתשלום, פשיטות רגל והליכי הוצאה לפועל, המעידים על חוסר היכולת של הלקוח לשלם את חובותיו; (2) ניצול אשראי מהווה 30% ממשקל הדירוג. בקריטריון זה נכללים נתונים כגון שיעור הניצול של מסגרות האשראי, מספר חשבונות האשראי שיש ללקוח וכן מקדמות ששולמו במסגרת הלוואות בתשלומים; (3) אורכה של היסטוריית האשראי מהווה 15% ממשקל הדירוג. ככל שתקופת השימוש בחשבונות אשראי ארוכה יותר, כך דירוג הלקוח יעלה; (4) מידת הגיוון של סוגי האשראי מהווה 10% ממשקל הדירוג. במסגרת קריטריון זה נבחנים סוגי האשראי של הלקוח, כגון משכנתאות, הלוואות לרכב וכרטיסי אשראי; (5) התנהגות פיננסית ערכנית של הלקוח מהווה 10% ממשקל הדירוג. בקריטריון זה נכללים נתונים דוגמת בקשות אשראי קודמות של הלקוח, תשלום חשבונות אשראי או הגדלת חיובים.¹²⁷ אולם לא לכל אוכלוסיית מבקשי האשראי הצרכני יש היסטוריית נתוני אשראי עשירה ומתועדת שתוכל להזין את המשקולות שתוארו לעיל. למעשה ישנן אוכלוסיות גדולות של מודרי אשראי (credit invisibles) שאינם מצליחים לגייס אשראי צרכני אך ורק משום שהם לא הצליחו ליצור תיעוד של נתוני אשראי.¹²⁸ כך למשל, מנתוני הרגולטור הפיננסי הצרכני בארצות הברית, ה־Consumer Financial Protection Bureau, עולה כי בשנת

122 ראו "DB Score דירוג אשראי" <https://www.dbisrael.co.il/dbcredit/> *dun&bradstreet* .db-score

123 ג'ניה וולינסקי "כשקנתי דירה לבת שלי והבנק הקפיץ לי את הריבית, הבנתי שיש לי בעיה בדירוג" *דה מרקר* (31.8.2020) <https://www.themarket.com/markets/.premium-1.9114024>

124 למדנו זאת משיחות שניהלנו עם נותני אשראי שונים, ראו לעיל בה"ש 27.

125 ראו לעיל בטקסט שליד ה"ש 83.

126 Gillis, לעיל ה"ש 18.

127 Daniel Faggella, *Machine Learning for Underwriting and Credit Scoring – Current Possibilities*, EMERJ (Apr. 3, 2020), available at <https://emerj.com/partner-content/.machine-learning-underwriting-credit-scoring>

128 Geselovich Packin & Lev-Aretz, לעיל ה"ש 83.

2015 היו בארצות הברית 26 מיליון מודרי אשראי, שהיו אז עשירית מכלל האוכלוסייה.¹²⁹ מחקרים הראו כי באוכלוסיית מודרי האשראי נכללים בעיקר לקוחות בעלי הכנסה נמוכה ומיעוטים אתניים.¹³⁰

כדי להרחיב את מעגל הזכאים לאשראי וכדי להתמודד עם היעדרה של היסטוריית נתוני אשראי בנוגע ללקוחות מסוימים, הרחיבו חברות דירוג בינלאומיות את בסיס הנתונים המשמש לבניית המודל להערכת סיכון האשראי של לקוחות, והחלו להשתמש בנתונים פיננסיים שאינם נתוני אשראי, כמו תשלומי שכירות וחיוכי חשמה וטלפון.¹³¹ כך למשל, בשנת 2015, הכריזה חברת FICO האמריקנית כי היא תחשב במנעד רחב יותר של נתונים להערכת סיכון אשראי, לרבות נתונים מחשבון הטלפון או מחשבון החשמה של הלקוח, נתונים על אודות נכסים של הלקוח ונתונים ממאגרים הפתוחים לעיון הציבור.¹³² גם ישראל צועדת בכיוון זה, והחל מיום 12 באפריל 2023 נתוני אשראי מחברת החשמה יוזרמו גם הם למאגר הלאומי.¹³³

השימוש בטכנולוגיות מתקדמות של למידת מכונה הוביל לכך שגם נתוני מידע שאינם פיננסיים הופכים להיות רלוונטיים לניבוי סיכון האשראי של הלקוח. בהתאם לכך אפשר למצוא דירוגי אשראי אלטרנטיביים שמפיקות חברות פרטיות, המתבססות על נתונים התנהגותיים שונים.¹³⁴

ניתוח ועיבוד של נתוני המידע לשם הפקת מודל לדירוג אשראי נעשים באמצעות שיטות אלגוריתמיות שונות.¹³⁵ ככלל, ניתן לסווג את השיטות האלגוריתמיות הללו לשני סוגים. הסוג הראשון מבוסס על סטטיסטיקות ליניאריות, הנחשבות פשוטות להבנה וליישום.¹³⁶ סטטיסטיקות ליניאריות, שלעיתים נעזרות גם בטכניקות פשוטות של למידת מכונה דוגמת גרסיה לוגיסטית (logistic regression), פועלות על מספר מוגבל של משתנים פיננסיים.¹³⁷

Kenneth P. Brevoort, Philipp Grimm & Michelle Kambara, *Data Point: Credit Invisible* (Financial Consumer Protection Bureau, May 2015), available at https://files.consumerfinance.gov/f/201505_cfpb_data-point-credit-invisibles.pdf

130 ש.ם.

131 Aggarwal, לעיל ה"ש 7, 47.

Annamaria Andriotis, *FICO Announces New Credit Score Based on Alternative Data*, WALL ST. J. (Apr. 2, 2015), available at <http://www.wsj.com/articles/fico-announces-new-credit-score-basedon-alternative-data-1427989748>

133 ס' 19 (ב) לחוק נתוני אשראי.

134 כך למשל, דירוג האשראי של Alibaba שנקרא "Sesame Credit". ראו בכתובת: <https://www.creditsesame.com>

135 Gillis, לעיל ה"ש 18.

136 Wang Bao, Ning Lianju & Kong Yue, *Integration of Unsupervised and Supervised Machine Learning Algorithms for Credit Risk Assessment*, 128 EXPERT SYSTEMS WITH APPLICATIONS 301, 301 (2019)

137 L. C. THOMAS, CONSUMER CREDIT MODELS: PRICING, PROFIT AND PORTFOLIOS 63 (2009)

למעשה הן מתבססות על מתאם סטטיסטי בין היסטוריית האשראי של הלקוח לסיכון האשראי שלו, ולפיכך אינן נעזרות במידע שאינו מבוסס על נתוני האשראי של הלקוח.¹³⁸ הסוג השני של שיטות אלגוריתמיות לניתוח ולעיבוד מידע לשם הפקת מודל דירוג אשראי מבוסס על טכניקות מתקדמות של למידת מכונה.¹³⁹ כיום, נוכח קיומן של שכבות מידע רבות ומגוונות על אודות לקוחות, השימוש בטכניקות של למידת מכונה לצורך הערכת סיכון אשראי הופך למרכזי.¹⁴⁰ בשונה מסוג השיטות הראשון, טכניקות אלה משקללות גם מידע שאינו פיננסי.¹⁴¹ טכניקות של למידת מכונה משתמשות בשיטות שונות. ניתן להבחין בין שיטות המבוססות על למידה שאינה מבוקרת (unsupervised learning) לבין שיטות שמבוססות על למידה מבוקרת (supervised learning). למידה לא-מבוקרת מאתרת קורלציות במידע לא-מסומן באופן עצמאי וללא הנחיות מראש. לעומת זאת, למידה מבוקרת מאתרת קורלציות במידע מוגבל ומסומן בהתאם להוראות שניתנות מראש.¹⁴² כפי שידרוב בהמשך, למידה לא-מבוקרת עשויה למזער את פוטנציאל ההפליה של מודל הדירוג.

אחת הטכניקות הפופולריות של למידת מכונה מבוקרת נקראת "יער אקראי" (Random Forest).¹⁴³ שיטה זו מבוססת על עצי הכרעה מסורתיים, שמפרקים את שאלת סיכון האשראי לתתי-שאלות קונקרטיות הבנויות על לוגיקה בינארית של "אם X אז Y".¹⁴⁴ שיטת היער האקראי מבוססת על שילוב אקראי של עצי הכרעה רבים למודל אחד כדי להגביר את דיוק הניבוי, ומכאן הכינוי "יער אקראי".¹⁴⁵ באופן כללי, שיטה זו דוגמת אקראית את המידע המסומן, ומאפשרת למודלים שונים של עצי הכרעה ללמוד מתוך המדגם ולנבא את סיכוי האשראי. מכיוון שכל עץ הכרעה מורכב מצמתים שונים, השילוב בין כל עצי הכרעה למודל אחד מעניק למודל גמישות ורגישות באשר למאפיינים ייחודיים. לאחר מכן מחושב

-
- Will Dobbie & Paige Marta Skiba, *Information Asymmetries in Consumer Credit Markets: Evidence from Payday Lending*, 5 AM. ECON. J. APPLIED ECON. 256 (2013) 138
- Alireza Hooman, et al., *Statistical and Data Mining Methods in Credit Scoring*, 50 J. DEVELOPING AREAS 371 (2016) 139
- Artem Beque & Stefan Lessmann, *Extreme Learning Machines for Credit Scoring: An Empirical Evaluation*, 86 EXPERT SYSTEMS WITH APPLICATIONS 42 (2017) 140
- Aggarwal, לעיל ה"ש 7, 47. 141
- Bao, Lianju & Yue, לעיל ה"ש 136, בעמ' 301-302. 142
- Majid Bazarbash, *FinTech in Financial Inclusion Machine Learning Applications in Assessing Credit Risk* (IMF Working Paper 109, 2019), available at <https://www.imf.org/en/Publications/WP/Issues/2019/05/17/FinTech-in-Financial-Inclusion-Machine-Learning-Applications-in-Assessing-Credit-Risk-46883> 143
- FinRegLab, *The Use of Machine Learning for Credit Underwriting: Market & Data Science Context* 59 FINREGLAB (2021), https://finreglab.org/wp-content/uploads/2021/09/The-Use-of-ML-for-Credit-Underwriting-Market-and-Data-Science-Context_09-16-2021.pdf 144
- Danny Yuan, *Applications of Machine Learning: Consumer Credit Risk Analysis*, MIT (2015), available at <https://dspace.mit.edu/bitstream/handle/1721.1/100614/932622145-MIT.pdf?sequence=1> 145

ממוצע של הניבויים השונים שהפיקו עצי ההערכה השונים כאשר לאותו מדגם נתונים כדי להפיק ערך מספרי.¹⁴⁶ כפי שיוסבר להלן, קבלת החלטה אם להעמיד ללקוח אשראי צרכני ובאילו תנאים מבוססת יותר ויותר גם על נתוני מידע אלטרנטיביים, דוגמת נתוני השכלה והיסטוריה תעסוקתית, נתונים על אודות פעילות ברשתות חברתיות, תדירות השימוש בטלפון חכם, נתוני כושר גופני, נתוני גלישה באתרי אינטרנט ועוד.¹⁴⁷ בזכות הרחבת בסיס המידע המשמש להפקת מודל דירוג אשראי מתקבלת תמונה מדויקת הרבה יותר כאשר לכושר הפירעון של הלקוח.¹⁴⁸ עם זאת הגם שעל פניו אין מדובר בקריטריונים מפלים, עיבודם האלגוריתמי עשוי להנציח הפליה היסטורית שגלומה בהם.¹⁴⁹

3. מודלים לחיתום אשראי

ככלל, חיתום אשראי הנעשה בידי המלווים כפוף למדיניות ניהול הסיכונים של המלווה הספציפי ונעשה על סמך מודלי החיתום הפנימיים שלו.¹⁵⁰ על פי רוב מודלי החיתום מבוססים על דירוגים הנרכשים מלשכות האשראי בצירוף מידע נוסף הנאסף בידי המלווים ממקורות אחרים.

המשקל שניתן לדירוגים איננו בהכרח מכריע. כך למשל, מחקרים אמפיריים מראים כי ככל שהשימוש בנתוני מידע אלטרנטיביים גדל במסגרת מודלי החיתום, כך פוחתת התלות בדירוג שמפיקות לשכות האשראי.¹⁵¹ משיחות שערכנו עם נותני אשראי בישראל – בנקאיים וחוף-בנקאיים – עלה כי משקלו של דירוג האשראי במודל החיתום של המלווה תלוי בגודלו ובמעמדו של המלווה. כך, מלווים גדולים טוענים כי מודל החיתום הפנימי שלהם, המבוסס על היסטוריה עשירה של נתונים גולמיים, מדויק יותר מדירוג האשראי של הלשכות שמבוסס על היסטוריה קצרה יחסית של נתוני אשראי (חמש שנים), ועל כן הדירוג שמתקבל מהלשכות משמש אך כאחד הנתונים שהם משקללים במסגרתו. נתון חשוב לא פחות לדידם הוא כושר ההחזר של הלקוח.¹⁵² לעומת זאת, מלווים חוף-בנקאיים ציינו בפנינו שהם כן מעניקים משקל מרכזי לדירוג האשראי של הלשכות במודלי החיתום שלהם.

146 ש.ם.

147 Tobias Berg, Valentin Burg, Ana Gombović & Manju Puri, *On the Rise of FinTechs – Credit Scoring Using Digital Footprints*, 33 REV. FIN. STUD. 2845 (2020); Daniel Björkegren & Darrell Grissen, *Behaviour Revealed in Mobile Phone Usage Predicts Credit Repayment*, 34 THE WORLD BANK ECON. REV. 618 (2020)

148 ש.ם.

149 ראו דיון להלן בפרק ג.3.

150 ישנם מלווים שנעזרים בחברות חיצוניות כדי לפתח מודלים לחיתום אשראי המופקים על סמך המידע הפנינסי שמחזיקים אותם מלווים. ראו: AnnaMaria Andriotis, *Shopping at Discount Stores Could Help Get You a Loan*, WALL ST. J. (May 4, 2019), available at <https://www.wsj.com/articles/use-a-landline-that-could-help-you-get-a-loan-from-discover-11551695400>. (להלן: Andriotis, *Shopping at Discount Stores*).

151 Jagtiani & Lemieux, לעיל ה"ש 15.

152 לעיל ה"ש 27.

ראוי לציין כי למלווים חוץ-בנקאיים (שאינם חברות כרטיסי אשראי) אין בדרך כלל היסטוריית נתוני אשראי עשירה כדי ליצור בעצמם מודלים לחיתום. זאת ועוד, חוק נתוני אשראי אינו מאפשר למלווים להשתמש במידע הגולמי הקיים במאגר לצורך הפקת מודל חיתום, אף לא בצורתו המותממת.¹⁵³ לפיכך, מלווים אלה נשענים לעיתים על מודלים לחיתום שמפתחות עבורם לשכות אשראי, על סמך הסיכונים הספציפיים שהם מגדירים.¹⁵⁴ מודלי החיתום הפנימיים של המלווים משקללים את דירוג האשראי האישי של הלקוח יחד עם נתוני מידע נוספים הנאספים עליו בידי נתוני האשראי ממקורות אחרים. כך למשל, מלווים שונים אוספים מידע לא-פיננסי העשוי לנבא את כושר הפירעון או את יכולת ההחזר של הלקוחות מבקשי האשראי, כגון ותק במקום העבודה, מספר שנות לימוד, המוסדות שבהם הלקוחות למדו ועוד.¹⁵⁵ הדרך הקלה להשגת נתונים אלה היא באמצעות קבלתם מהלקוחות. לקוחות מתבקשים לספק תלושי משכורת, דוחות מבנקים ומגופים פיננסיים¹⁵⁶ ונסחי טאבו המעידים על נכסי נדל"ן, ואף לענות על שאלון מפורט. כמו כן, מידע על אודות הפעילות הבנקאית של הלקוח מתקבל באמצעות מערכת הבנקאות הפתוחה. כל אלה מצטרפים למידע ההיסטורי המצוי בידי המלווה על הלקוח, ככל שקיים מידע כזה.

לצד הנתונים הפיננסיים-כלכליים והמידע הנוסף המתואר לעיל, מודלים לחיתום אשראי עשויים לכלול גם מידע התנהגותי וחברתי על אודות הלקוח. כך למשל, חברות כרטיסי אשראי משתמשות במידע שיש להן על הרגלי הרכישה של הלקוחות ואף במידע על עסקאות ספציפיות.¹⁵⁷ למעשה, טכנולוגיות מתקדמות של למידת מכונה מסוגלות להצביע על רלוונטיות של מגוון נתוני מידע אלטרנטיבי על אודות הלקוח לצורך הערכת

153 החוק מאפשר למלווים – באמצעות לשכות אשראי – לקבל רק מידע על אודות מבקש האשראי הספציפי. ראו על כך לעיל בפרק א.1.

154 לשכות אשראי רשאיות לספק לנתוני אשראי שירותים נוספים, ובכלל זה בניית מודלי דירוג, ראו לעיל ה"ש 56.

155 Aggarwal, לעיל ה"ש 7, בעמ' 46.

156 בישראל הבנקים מחויבים להנפיק ללקוח דוח שנתי הכולל מידע על אודות כלל הנכסים וההתחייבויות שלו בבנק, לרבות סך ההכנסות וההוצאות שהיו לו במהלך השנה בגין פעילותו הבנקאית. הדוח כולל מידע רב, לרבות יתרות בחשבונות ובפיקדונות השונים, יתרות הלוואות ובכלל זה משכנתאות, וכן נתונים על הפעילות כגון יתרה חודשית ממוצעת, שיעור ריבית שנתי ממוצע, סכומי ריבית ששולמו או שהתקבלו בחשבונות השונים, רווח או הפסד מניירות ערך, סכומי העמלות ששולמו ועוד. ראו: הוראת ניהול בנקאי תקן 425 "דוחות שנתיים ללקוחות התאגידים הבנקאיים" (ערכון 13.6.2022) <https://www.boi.org.il/he/BankingSupervision/SupervisorsDirectives/Pages/nihultakin.aspx>. עם זאת רוב הלקוחות אינם מודעים כלל לדוח זה המצוי בעמוד האישי שלהם באתר האינטרנט של הבנק. ראו: ג'ניה וולנסקי "הבנקים מרוצים: הכלי שנועד לעודד תחרות – נשכח על ידי הציבור" **דה מרקר** (16.9.2020) <https://www.themarker.com/markets/premium-1.9158295>.

157 עניין זה התעורר לאחרונה עם כניסת חברות כרטיסי האשראי לתחום הביטוח, על בסיס המידע שיש להן על אודות הלקוחות שלהן. ראו: עירית אבישר "האתגר של ישראל: מינוף המידע על לקוחות למחיר משתלם" **כלכליסט** (20.7.2021) <https://www.calcalist.co.il/investing/article/by600eqxau>.

סיכון האשראי שלו, גם אם מדובר במתאם שאיננו טריוויאלי ממבט ראשון.¹⁵⁸ כך למשל, חברות אשראי מצאו קשר בין היזקקות לטיפול זוגי בשל בעיות בחיי הנישואין לבין סיכון אשראי גבוה.¹⁵⁹ אכן, ככל שמדע הנתונים הלך והשתכלל ועימו גם היכולת למצוא קורלציות מפתיעות ולא-צפויות בין משתנים, כך גדל גם מגוון הנתונים הפוטנציאלי שיכול לנבא סיכון אשראי של לקוח.¹⁶⁰

לא בכדי החלו לצוץ מאז ראשית שנות האלפיים בשוק האמריקני ואף בישראל חברות טכנולוגיה פיננסית (FinTech) רבות, שמתמקצעות בניחוח נתוני עתק באמצעות למידת מכונה לשם בניית מודלים מדויקים יותר להערכת סיכון האשראי של לקוחות.¹⁶¹ חברות אלה מנתחות כמויות מידע עצומות, לרבות סרטונים, תמונות ושמע,¹⁶² כדי למצוא אינדיקציות מהימנות לסיכון אשראי.¹⁶³ חלקן אף נעזרות במידע שנשמר על גבי מכשירים חכמים הפועלים בטכנולוגיה של "האינטרנט של הדברים" (The Internet of Things) כדי ללמוד על סיכון האשראי של לקוחותיהם.¹⁶⁴

השימוש בטכנולוגיות מתקדמות של למידת מכונה כדי לעבד ולנתח כמויות מידע עצומות אלו מאפשר למלווים לפתח מודלים דינמיים לחיתום אשראי, המסוגלים לשקף שינויים באוכלוסייה ושינויים סביבתיים על מנת להעריך בצורה מדויקת יותר את סיכון האשראי של הלקוח. כך למשל, ניתן לקזז מידע ישן על אודות כשל אשראי עם מידע מעודכן יותר באשר לעמידה בחובות או לשקלל הכנסות עתידיות מהסדרי שכר גמישים יותר. זאת ועוד, השימוש בטכנולוגיות אלו להערכת סיכון אשראי ממזער את ההשפעה של טעות בנתוני הלקוח, שכן המשקל שניתן לכל נתון מידע במסגרת המודל פוחת משמעותית.¹⁶⁵

158 *Andriotis, Shopping at Discount Stores*, לעיל ה"ש 150.

159 Lior Jacob Strahilevitz, *Toward a Positive Theory of Privacy Law*, 126 HARV. L. REV. 2010, 2021 (2013).

160 Aggarwal, לעיל ה"ש 7, בעמ' 46.

161 ראו בישראל: ליאורה בורסקי "ההזדמנות העסקית של חברות הפינטק הישראליות" דה מרקר (26.9.2021), <https://www.themarker.com/labels/financial-technology/1.10242894>. ככלל, חלק מחברות הפינטק מפתחות את המודל על סמך מידע שנאסף בידי המלווים, ואילו אחרות אוספות בעצמן את המידע הדרוש להן לצורך פיתוח המודל. ראו: Katja Langenbucher & Patrick Corcoran, *Responsible AI Credit Scoring – A Lesson from Upstart.com*, in DIGITAL FINANCE IN EUROPE: LAW, REGULATION, AND GOVERNANCE 142, 147-148 (5 ECFR – Special Volume, Emiliios Avgouleas & Heikki Marjosola eds., 2021).

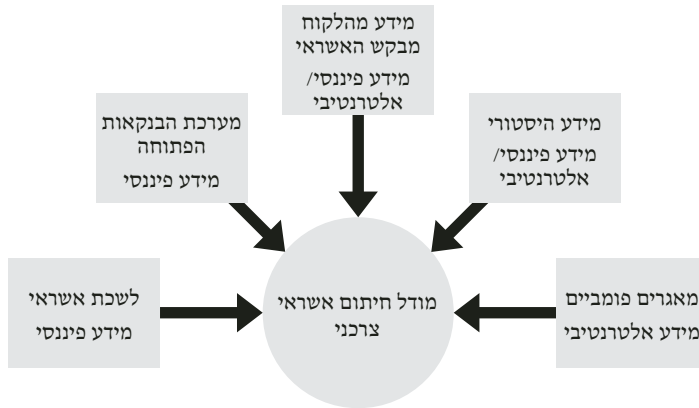
162 שם.

163 Geslevich Packin & Lev-Aretz, לעיל ה"ש 83, בעמ' 16.

164 שם.

165 Aggarwal, לעיל ה"ש 7, בעמ' 47.

תרשים 1: מקורות וסוגי המידע העשויים להרכיב מודל חיתום לאשראי צרכני



ג. הפליה בחיתום אשראי

1. הפליה אסורה מול הבחנה מותרת

למודלים אלגוריתמיים יתרונות חשובים לצורך חיתום אשראי, ומכאן נובעת מרכזיות השימוש בהם בארץ ובעולם.¹⁶⁶ עם זאת מתעוררת השאלה אם אין בהם כדי לגרום להפליה. בהקשר זה חשוב להבחין בין הפליה אסורה לבין הבחנה המותרת לעוסק בשוק הפרטי מטעמים ענייניים.

העמדת אשראי מעמידה את המלווה בסיכון של אי-פירעון האשראי. סיכון זה הוא מהותי במיוחד בקרב גופים המחזיקים בידיהם כספי לקוחות, כגון הבנקים, בשל החשש שאי-פירעון בהיקף גדול עלול לערער את יציבותם. שיקול היציבות אינו אינטרס פרטי של הבנקים, כי אם אינטרס המשותף לכלל לקוחותיהם, לציבור המשקיעים בבנק, לנושים השונים של הבנק ואף לציבור בכללותו, לאור מעמדם המרכזי של הבנקים בחיי הכלכלה ולנוכח הפגיעה שתיגרם למשק כולו במקרה של התמוטטות בנק.¹⁶⁷ שיקול היציבות הוא שיקול מרכזי של המערכת הבנקאית, המחייב בחינה יסודית של סיכון האשראי וסירוב להעמיד אשראי ללקוחות מסוכנים.¹⁶⁸ מסיבה זו הבנקים רשאים – ואף חייבים על פי הוראות הרגולטור¹⁶⁹ – להבחין בין לקוחות בעלי מוסר תשלומים גבוה לבין לקוחות בעלי

166 ראו לעיל במבוא.

167 RUTH PLATO-SHINAR, BANKING REGULATION IN ISRAEL: PRUDENTIAL REGULATION VERSUS CONSUMER PROTECTION, chap. 1 (2016).

168 רע"א 9374/04 אי. אנד. ג"י. מערכות מתקדמות למורה נהיגה בע"מ נ' בנק לאומי לישראל בע"מ, פס' 6 (ג) (נבו 11.11.2004).

169 ראו למשל: בנק ישראל: הפיקוח על הבנקים: הוראת ניהול בנקאי תקין 311 "ניהול סיכון אשראי" ס' 4, 15, ח' 26, 27, 32 (עדכון 30.9.2021) (להלן: הוראת ניהול בנקאי תקין 311);

מוסר תשלומים נמוך, או בין לקוחות בעלי כושר פירעון מוכח לבין כאלו שמתעורר ספק באשר ליכולת ההחזר שלהם.

ההכרה בזכותו (ואף בחובתו) של הבנק לבצע הבחנה שכזו בין לקוחות נובעת לא רק מהצורך להגן על הבנק, אלא גם מהצורך להגן על הלווים עצמם. מתן אשראי מעמיד בסיכון גם את הלווים, שכן אי-פירעון האשראי עלול לסבכם מבחינה כלכלית ומשפטית ולדרדר את מצבם. אחת הבעיות שנצפו בשנים האחרונות היא נטייה של צרכנים ליטול אשראי בהיקפים גבוהים שבהם הם לא יוכלו לעמוד, תופעה המהווה "מינוף יתר". בסיבות לכך ניתן למנות הטיות קוגניטיביות שונות, ובהן אופטימיות יתר, הערכת חסר של מצבם הכלכלי האמיתי ועוד.¹⁷⁰ הגנה על הלווים מחייבת אפוא הבחנה בין לוויים בעלי יכולת פירעון ללווים הנעדרים יכולת זו, כמו גם בחינה של מוסר התשלומים של הלווה.

הבחנה בין לקוחות לפי כושר הפירעון ומוסר התשלומים שלהם משפרת את מצבם של הלווים האיכותיים. לפני הכול היא מאפשרת להפחית את עלויות הריבית שלהם. כמו כן, לאור העובדה שהיקף מקורות האשראי העומדים לרשות המלווים השונים הוא מוגבל, הרי סירוב להעמיד אשראי ללווים בעייתיים מותר יותר אשראי פנוי בידי המלווים, ומגדיל את סיכויים של הלווים האיכותיים יותר לקבל את האשראי המבוקש.

הבחנה זו בין לקוחות מתבקשת גם מכוח שיקולי יעילות כלכלית כלל-משקית. הבחנה שכזו מפחיתה סבסוד צולב בין לקוחות, היינו מצב שבו לקוחות ברמת סיכון נמוכה מחויבים בריבית גבוהה יותר שאינה תואמת את רמת הסיכון שלהם, בעוד שלקוחות ברמת סיכון גבוהה יחויבו בריבית נמוכה יותר רק בשל היעדר יכולת להבחין בין הלקוחות.

לבסוף, יש מי שמצדדים אף בגישה מרחיבה יותר, ולפיה ניתן להצדיק הבחנה כלכלית בין לקוחות – שאינה מושתתת על תבחינים אסורים אך תוצאתה העקיפה עלולה להוביל ליחס שונה כלפי לקוחות שונים – כאשר היא נדרשת לקידום האינטרס העסקי של המלווה (legitimate-business-necessity defense).¹⁷¹ שימוש בטכניקות אלגוריתמיות שמטרתן לצמצם סיכוני אשראי ואף להפחית עלויות או להגביר רווחיות עשוי להיחשב לגיטימי אף אם תוצאתן העקיפה של טכניקות אלה היא מתן יחס לא-שווה לקבוצות שונות, בפרט נוכח ההוכחות בדבר יעילות המודלים האלגוריתמיים ורמת הדיקו הגבוהה שלהם.¹⁷² ככל שידוע לנו, טענה שכזו טרם נדונה בישראל בנוגע לחיתום אשראי.¹⁷³

הוראת ניהול בנקאי תקין 311A "ניהול אשראי צרכני" ס' 16, 23, 24, 26, 27, 28 (עדכון 30.9.2021). ההוראות זמינות בכתובת <https://www.boi.org.il/he/BankingSupervision/SupervisorsDirectives/Pages/nihultakin.aspx>.

170 Oren Bar-Gill, *Seduction by Plastic*, 98 Nw. U. L. Rev. 1373, 1407 (2004). לתופעה זו בהקשר הצרכני הכללי, ראו: שמואל בכר "תוכן קונקרטי לדוקטרינות עמומות: ניתוח התנהגותי של חוזים צרכניים" **עיוני משפט** לג 277, 282 (2010).

171 Bartlett et al, לעיל ה"ש 18.

172 Policy Statement on Discrimination in Lending, 59 Fed. Reg. 18266, 18268 (Apr. 15, 1994). לניתוח גישה זו, ראו: Katja Langenbacher, *Responsible AI-Based Credit Scoring* (2020). Barocas & Selbst, 31 EBLR 527, 549, 553-54 (2020). לעיל ה"ש 16, בעמ' 671, 702 ואילך, 723 ואילך (בריני עבודה).

173 הגנת האינטרס העסקי נדחתה בבג"ץ 6051/95 רקנט נ' בית הדין הארצי לעבודה (נבו 24.6.1997)

לעומת זאת, הבחנה בין לקוחות על סמך תבחינים אסורים, דוגמת גזע, דת או לאום היא הפליה פסולה.¹⁷⁴ ישנם שני סוגים של הפליה פסולה: הפליה מכוונת והפליה בלתי-מכוונת.¹⁷⁵ הפליה מכוונת (disparate treatment או taste based discrimination) עניינה שימוש מכוון בתבחינים אסורים במסגרת חיתום אשראי. שימוש שכזה הוא בגדר הפליה אסורה, בין אם החיתום נעשה בידי בן אנוש ובין אם הוא נעשה בידי אלגוריתם. אולם החלפת שיקול הדעת האנושי בשיקול דעת אלגוריתמי, המבוסס רק על נתוני מידע שאינם כוללים תבחינים אסורים במישרין, פותרת בעיות של הפליה מכוונת.¹⁷⁶ לעומת זאת, הפליה בלתי-מכוונת (disparate impact) עניינה מקרים שבהם אמות המידה למתן אשראי הן ניטרליות לכאורה, אולם בפועל הן מביאות ליחס מפלה.¹⁷⁷ כפי שיורחב להלן, הפליה שכזו עלולה להתרחש במקרים שבהם המידע המשמש להערכת סיכויי האשראי של הלקוח הוא תוצר של פרקטיקות היסטוריות מפלות או כאשר המידע הוא אינדיקציה לתבחין אסור, גם אם המידע כשלעצמו הוא ניטרלי. הפליה בלתי-מכוונת עשויה גם להיגרם משיטת ניתוח המידע. הפליה מסוג זה, הקשה יותר לגילוי, תידון בהרחבה בהמשך פרק זה.

2. חיתום אשראי אלגוריתמי: הפליה מול הכלה

הגם שמאמר זה מתמקד בקיומו של חשש להפליה בחיתום אשראי אלגוריתמי, חשוב להדגיש כי ממבט-על קשה לזהות מגמה חד-משמעית בעניין זה.¹⁷⁸ אף שמודלים אלגוריתמיים לחיתום אשראי עלולים להעמיק את ההפליה בהקשרים מסוימים, בה בעת הם עשויים לצמצמה בהקשרים אחרים.

כך למשל, נמצא כי השימוש בחיתום אשראי אלגוריתמי בשוק המשכנתאות עלול להפלות בין מלווים מקבוצות מיעוט למלווים שאינם מקבוצות מיעוט.¹⁷⁹ מחקר אחר שערכו חוקרים מאוניברסיטת ברקלי מצא הפליה בהעמדת אשראי צרכני על סמך דירוג אלגוריתמי, המתבטאת בכך שאפרו-אמריקנים והיספאנים משלמים 5.6 עד 8.6 נקודות בסיס יותר בשיעור הריבית ברכישת בתים לעומת לבנים או אסיאתים בעלי נתוני אשראי דומים.¹⁸⁰ בישראל טרם נחשפו נתונים באשר לפילוג מדורגי האשראי, הגם שבמסגרת הדיווח השנתי של בנק ישראל, לוועדת הכלכלה מיום 23 במאי 2021 צוין, כי "קיומה של אפליה

כנגד דעת המיעוט של השופט חשין, שם, בעמ' 316-317. אולם באותו מקרה דובר בהפליה מחמת גיל, היינו שימוש ישיר בתבחין אסור. לעומת זאת, בחיתום אשראי אלגוריתמי שאינו מבוסס על תבחינים אסורים ותוצאתו העקיפה בלבד היא הבחנה בין לקוחות, ייתכן שטענת האינטרס העסקי תתקבל.

174 ס' 3 (א) לחוק איסור הפליה.

175 Barocas & Selbst, לעיל ה"ש 16, בעמ' 694. Langenbucher, לעיל ה"ש 172, בעמ' 546-550.

176 Bartlett et al., לעיל ה"ש 18, בעמ' 2.

177 ראו למשל New York State Department of Financial Services, *Report on Apple Card Investigation 5* (Mar., 2021), https://www.dfs.ny.gov/system/files/documents/2021/03/rpt_202103_apple_card_investigation.pdf

178 Fuster et al., לעיל ה"ש 19.

179 שם, בעמ' 8.

180 Bartlett et al., לעיל ה"ש 18.

במתן אשראי" הוא אחת הסוגיות הנחקרות בידי בנק ישראל.¹⁸¹ מנתוני בנק ישראל עולה, כי ישנם אחוזים לא־מבוטלים של אזרחים ישראלים בעלי דירוג אשראי נמוך (8% מכלל הלקוחות שבמאגר נתוני האשראי נכון לסוף שנת 2021) או חסרי דירוג אשראי (10% מכלל הלקוחות שבמאגר נתוני האשראי נכון לסוף שנת 2021), כלומר שתי קבוצות שאינן מצליחות לקבל אשראי, מצב שעלול להוביל להדרת אשראי.¹⁸²

מנגד, הרחבת בסיס הנתונים המשמשים להפקת מודל חיתום, יחד עם השימוש בטכנולוגיות מתקדמות של למידת מכונה, נתגלו במקרים רבים דווקא כמסייעים לאוכלוסיות מוחלשות, אשר סורבו בקבלת אשראי רק בשל היסטוריית אשראי דלה שלא אפשרה למלווה להעריך את מצבם.¹⁸³ בהקשר זה השימוש בדירוג אלגוריתמי, המבוסס על ריבוי של פרטי מידע מסוגים שונים ובכלל זה מידע אלטרנטיבי, עשוי להגביר את התחרות ואת הנגישות בשוק האשראי.¹⁸⁴ ואכן זו הייתה המטרה שעמדה לנגד עיניהם של קובעי המדיניות בישראל בעת חקיקת חוק נתוני אשראי והקמת מאגר נתוני האשראי בבנק ישראל.¹⁸⁵

כך למשל, מחקר שבחן לאחרונה את הקשר שבין שימוש בנתונים שאינם פיננסיים לצורך הערכת סיכון אשראי בארצות הברית מצא, כי ההסתברות שלקוחות בעלי דירוג אשראי נמוך מ־640 אשר קיבלו אשראי מחברת פינטק שמשקללת נתונים אלטרנטיביים במסגרת מודל החיתום שלה (Upstart Network) יקבלו אשראי ממלווים שאינם משקללים נתונים שאינם פיננסיים היא 40%.¹⁸⁶ לעומת זאת, עבור לקוחות בעלי דירוג גבוה מ־740 נמצא כי אין הבדל בסיכוי לקבל הלוואה בין מלווה שאינו משקלל נתונים שאינם פיננסיים למלווה שכן משקלל נתונים שכאלו.¹⁸⁷ מסקנת המחקר היא, כי שקלול נתונים אלטרנטיביים במסגרת מודל החיתום מיטיב עם לווים בעלי היסטוריית אשראי דלה, בעיקר כאלו המחזיקים בתארים אקדמיים ובעבודות בשכר, מבלי לפגוע ברווחיות המלווים.¹⁸⁸ בדומה לכך, הרגולטור הפיננסי האמריקני, ה־Consumer Financial Protection Bureau, מצא כי השימוש בניתוח נתוני מידע אלטרנטיביים באמצעות למידת מכונה הביא לכך שמודלים לחיתום אשראי אלגוריתמי מאשרים 27% יותר בקשות אשראי. זוהי לטענתו אינדיקציה לכך, שאוכלוסיות שהיו בעבר מודרות אשראי עתידות להימצא זכאיות לאשראי בעתיד הקרוב.¹⁸⁹

181 דיווח לוועדת הכלכלה 2021, לעיל ה"ש 33, בעמ' 3. ראו גם דיווח לוועדת הכלכלה 2022, לעיל ה"ש 33, בעמ' 3, המדגיש את הקשיים שבעריכת מחקר שכזה.

182 שם, בעמ' 19–20.

183 Aggarwal, לעיל ה"ש 7, בעמ' 54, 56.

184 סוגיה גורודיסקי "מי יציל את הבית שלי? בין דירוג האשראי ושוק המשכנתאות" וואלה כסף Marco De Maggio et al, *Invisible Primes: Fintech Lending with Alternative*; (4.7.2021) *Data*, HARVARD BUSINESS SCHOOL (Working Paper 22-24, 2021).

185 ס' 1(א)(1) לחוק נתוני אשראי.

186 De Maggio et al., לעיל ה"ש 184, בעמ' 4.

187 שם.

188 שם, בעמ' 5.

189 Patrice Ficklin & Paul Watkins, *An Update on Credit Access and the Bureau's First No-Action Letter*; CFPB (Jun. 8, 2019), available at

[/https://www.consumerfinance.gov/about-us/blog/update-credit-access-and-no-actionletter](https://www.consumerfinance.gov/about-us/blog/update-credit-access-and-no-actionletter)

עם זאת, גם אם לשימוש בחיתום אשראי אלגוריתמי עשויות להיות השלכות חיוביות על ערך השוויון, אין בכך כדי לייתר לדעתנו את הצורך לבחון ולהתייחס לחשש להפליה. כלומר, אפילו אם בראייה מצרפית חיתום אשראי מצמצם את אי־השוויון בתחום העמדת אשראי צרכני כלפי לקוחות מסוימים, אין בכך בהכרח כדי לצמצם או אף להעלים את החשש להפליה באשר ללקוחות אחרים.

הסיבות שבגינן השימוש במודלים אלגוריתמיים לחיתום אשראי עלול להוביל להפליה הן שונות ומגוונות. חלקן עשויות להתקשר לגורמים חיצוניים למודל האלגוריתמי, כגון היעדר אוריינות טכנולוגית ופיננסית בקרב אוכלוסיות מוחלשות. אוכלוסיות אלו עלולות להתקשות להבין את הפרמטרים המשפיעים על דירוג האשראי, ובהתאם לכך לנהל את התנהגותן הפיננסית בהווה באופן שמשפיע לרעה על דירוג האשראי שלהן בעתיד.¹⁹⁰ כך למשל, איחור חד־פעמי בתשלום המשכנתה עלול לפגוע בדירוג האשראי בצורה קיצונית, עד כדי כך שבקשת הלוואה מצד הלקוח המאחר תסורב.¹⁹¹ ישנו חשש כי לווים מקרב אוכלוסיות מוחלשות לא ימהרו לבדוק את סיבת הסירוב (בגלל אי־הבנת חשיבות הנושא או בגלל קשיים טכנולוגיים הנדרשים לשם קבלת המידע), וכפועל יוצא לא ילמדו כיצד להתנהל נכון מבחינה פיננסית.

סיבות אחרות להפליה בעקבות חיתום אשראי אלגוריתמי נובעות מגורמים פנימיים למודל, ובהן עוסק פרק זה. מבחינה זו אפשר למנות שתי סיבות מרכזיות שבגינן השימוש במודלים אלגוריתמיים לחיתום אשראי עשוי להוביל לתוצאות מפלות: הסיבה הראשונה נעוצה בהפליה שמוכנית בפריטי המידע המשמשים לבניית המודלים; הסיבה השנייה קשורה לסוג המודל האלגוריתמי שבו יש שימוש. נדון בכל אחת מסיבות אלה להלן.

יודגש כי הדיון הוא תאורטי בעיקרו, משום שמודלים לדירוג ולחיתום אשראי אינם כפופים לעיון הציבור בהיותם קניין רוחני של הלשכות ושל המלווים בהתאמה.¹⁹² אכן, שמירה על סודיות המודלים מקנה לבעליהם יתרון תחרותי חשוב.¹⁹³ לפיכך אין באפשרותנו לבחון את הקריטריונים הספציפיים המובאים בחשבון במסגרת פיתוח מודל החיתום, או להעריך מהו המשקל שניתן לכל אחד מהם במסגרת החלטה הנוגעת להעמדת אשראי. עם זאת יש חשש כי האינטרס הכלכלי של המלווים בחיזוי מדויק של סיכון האשראי עלול להובילם לפיתוח מודלי חיתום יעילים מבחינתם, אך כאלה שעלולים במקרים שונים ליצור הפליה.

3. הפליה היסטורית המובנית בפריטי המידע

מבחינת טיב המידע המשמש לבניית מודלים, ברי כי ככל שהמודל מבחין בין לקוחות על בסיס משתנים שמזוהים עם קבוצות מסוימות של דת, של גיל, של מגדר, של גזע וכן

190 גורודיסקי, לעיל ה"ש 184.

191 ג'ניה וולנסקי "מהו דירוג אשראי, מה נחשב לציון טוב – ואיך ניתן לשפר אותו?" דה מרקר (20.9.2021) https://www.themarker.com/markets/.premium-1.10220031?lts=1632204502231&_ga=2.16900603.316539185.1639305458-1568435703.1635244174

192 ראו למשל, De Maggio et al, לעיל ה"ש 184, בעמ' 2.

193 שם.

הלאה, אזי גם תוצאות המודל יבחינו בין קבוצות אלה.¹⁹⁴ מטעם זה פרקטיקה שכזו אסורה במדינות השונות, לרבות ישראל.¹⁹⁵ אולם איסור זה אינו פותר את החשש להפליה, מאחר שהשימוש במודלים אלגוריתמיים לחיתום אשראי מנבא את סיכון האשראי על סמך מידע קיים בנוגע ללקוחות, אשר עשוי בעצמו לשקף פרקטיקות מפלות. פיתוח מודל אלגוריתמי על סמך מידע גולמי מוטה עלול להוביל לשעתוק של הפליה היסטורית.¹⁹⁶ הטענה בהקשר זה היא, כי טכנולוגיות בינה מלאכותית אינן טובות יותר מהמידע הגולמי ששימש ליצירתן.¹⁹⁷ כך למשל, דירוג Fico האמריקני משקלל בין היתר את היסטוריית התשלומים של הלקוח. היסטוריית התשלומים כוללת מידע הנוגע לפירעון חובות בידי הלקוח, לרבות פירעון הלוואות בריבית סאב־פריים. הבעיה היא שבמשך שנים אפרו־אמריקנים והיספאנים סבלו מהפליה והתקשו לקבל הלוואות מבנקים, מה שהסליל את דרכם לקבלת הלוואות סאב־פריים. הלוואות סאב־פריים מבוססות על ריבית גבוהה מאוד לעומת הלוואות בריבית קבועה, כמו גם על תנאים נוספים המקשים על פירעון, לא בהכרח בגלל תכונותיו הספציפיות של הלווה אלא בשל מאפייניה המיוחדים של ההלוואה.¹⁹⁸ עקב כך שיעור גבוה של לווים מתקשה לפרוע את ההלוואות האמורות. מכיוון שעיקר הלווים בהלוואות אלה הם קבוצות האוכלוסייה האמורות, המידע יצביע על שיעורי הפרה גבוהים באשר לאוכלוסיות אלו. בעקבות זאת, מודל חיתום אלגוריתמי שיופק על בסיס מידע הנוגע להיסטוריית התשלומים עשוי לשעתק את ההפליה במתן אשראי על בסיס גזע.¹⁹⁹

מחקר שבדק שתי קבוצות של לווים זהים בעלי הכנסות זהות, האחת שקיבלה הלוואות בריבית קבועה נמוכה והשנייה שקיבלה הלוואות סאב־פריים, השווה את שיעור ההפרות בכל קבוצה. המחקר מצא כי המשתנה השונה היחיד בין שתי הקבוצות נגע לתנאי ההלוואה ולאפיק שבאמצעותו השתמשו הלווים כדי לקבל את ההלוואה.²⁰⁰ אף על פי כן, שיעור ההפרות בהלוואות סאב־פריים היה גבוה פי ארבעה משיעור ההפרות בהלוואות בנקאיות, נתון שהשפיע השפעה שלילית על דירוג האשראי של הלווים. כלומר, עצם קיומן של הלוואות סאב־פריים היסטוריות, שאופייניות לאוכלוסיות האפרו־אמריקנים וההיספאנים

194 Gillis, לעיל ה"ש 18, בעמ' 41.

195 ראו להלן בפרק ד.1.

196 Amy J. Schmitz, *Secret Consumer Scores and Segmentations: Separating Consumer "Haves" from "Have-Nots"*, 2014 MICH. ST. L. REV. 1411; Sandra G. Mayson, *Bias* In, *Bias Out*, 128 YALE L.J. 2218 (2019). Barocas & Selbst

197 Chris DeBrusk, *The Risk of Machine-Learning Bias (and How to Prevent It)*, MIT SLOAN MGMT. REV. (2018), available at <https://sloanreview.mit.edu/article/the-risk-of-machine-learning-bias-and-how-to-prevent-it>

198 Lisa Rice & Deidre Swesnik, *Discriminatory Effects of Credit Scoring* 18 (National Fair Housing Alliance, 2012), available at <https://nationalfairhousing.org/wp-content/uploads/2017/04/NFHA-credit-scoring-paper-for-Suffolk-NCLC-symposium-submitted-to-Suffolk-Law.pdf>

199 שם.

200 Lei Ding et al., *Risky Borrowers or Risky Mortgages: Disaggregating Effects Using Propensity Score Models*, 33 J. REAL ESTATE 245 (2011)

בארצות הברית, פגע בדירוג האשראי שלהם, ללא שום קשר למסוגלות הפיננסית שלהם ולמוסר התשלומים שלהם בפועל.²⁰¹

תוצאות דומות עלולות להתרחש גם בישראל, בעקבות עיבוד אלגוריתמי של נתוני מידע חוקיים שלכאורה אינם מפלים. כך למשל, חשש להפליה המובנית במידע עולה משיעורם הנמוך של ערביי ישראל בקרב מקבלי המשכנתאות בישראל.²⁰² נתונים שפורסמו בחודש דצמבר 2021 מראים כי אף שהציבור הערבי מהווה 20% מאוכלוסיית ישראל, הוא מקבל רק 2% מהמשכנתאות בישראל.²⁰³ הסיבות להבדלים אלו מגוונות ואינן נוגעות אך ורק לנתונים הכלכליים של האוכלוסייה הערבית, דוגמת הכנסה ממוצעת נמוכה למשק בית.²⁰⁴ בפרט, נטען כי שיעור המשכנתאות הנמוך בחברה הערבית נובע גם מהיעדר פעילות של ייעוץ משכנתאות בחברה זו, מקושי ברישום נכסים וקרקעות ביישובים ערביים לצורך רישום משכנתאות, ומהיעדר אוריינות פיננסית (עקב נגישות מוגבלת לשירותים בנקאיים) אשר מוביל הן לחוסר ידע בכל הנוגע לאפשרויות הפיננסיות והן ליכולת מיקוח מוגבלת מול הבנקים.²⁰⁵ במילים אחרות, נתוני המשכנתאות הנמוכים בחברה הערבית אינם נובעים בהכרח ממוסר תשלומים נמוך או ממאפיינים אישיים בעייתיים של מבקשי האשראי. ככל שנתונים אלו נובעים גם מהפליה היסטורית (כך למשל, אם הנגישות המוגבלת לשירותים פיננסיים ולשירותי ייעוץ משכנתאות נובעת מהפליה מכוונת), הרי השימוש בהם לצורך פיתוח מודל אלגוריתמי עלול לשעתק את אותה הפליה. במילים אחרות, ככל שהמלווים משקללים נתונים על אודות קיומה של משכנתה כנתונים חיוביים במסגרת מודל חיתום האשראי שלהם, הרי שקלול זה עלול להוביל לשעתוק של הפליה אסורה מטעמי לאום. בדומה לכך, מידע שמקורו בהסדרי הבנקאות הפתוחה עלול גם הוא להוביל להפליה אסורה. כך למשל, שיתוף מידע בנוגע לריביות המשולמות על הלוואות עלול להנציח הפליה הנוגעת לקבוצות מוחלשות שמבחינה היסטורית נאלצו להישען על הלוואות בריבית גבוהה בשל תזרים הכנסות נמוך, ללא קשר לסיכון האשראי שלהן.

דוגמה נוספת קשורה לתחום ההשקעות. מערכת הבנקאות הפתוחה מתוכננת לכלול בעתיד גם מידע על השקעות בשוק ההון. רובם המכריע של השחקנים בשוק ההון הם גברים.²⁰⁶

201 Rice & Swesnik, לעיל ה"ש 198, בעמ' 18-19.

202 מתן שחק משכנתאות בישראל – פילוח לפי מגזר (הכנסת, מרכז המחקר והמידע, 26.5.2015) https://fs.knesset.gov.il/globaldocs/MMM/af1007dc-1277-e511-80d1-00155d0ad6b2/2_11_9174.pdf (מכתב המסביר כי לפי סקר ארוך טווח שביצעה הלשכה המרכזית לסטטיסטיקה, בשנת 2013 הייתה רק ל-7% ממשקי הבית הערביים משכנתה בהשוואה ל-33% ממשקי הבית היהודיים).

203 הדר חורש "התוכנית לפתרון מצוקת המשכנתאות ביישובים הערביים: ערכות מדינה ב-10 מיליארד שקל" **דה מרקר** (6.12.2021) 1.10444468 <https://www.themarket.com/realestate/premium-1.10444468>.

204 שם.

205 שם.

206 Laurie Itkin, *Why Don't More Women Invest in the Stock Market?*, WHARTON MAGAZINE (Dec. 10, 2014), available at <https://magazine.wharton.upenn.edu/digital/why-dont-more-women-invest-in-the-stock-market>.

אם הכלים האלגוריתמים יעניקו משקל חיובי לפעילות בשוק ההון, הרי מודל המופק על סמך מידע זה עלול להוביל לדירוג גבוה יותר לגברים ולגרום להפליה אסורה מטעמי מין. הפליה המובנית בפריטי המידע עלולה להתרחש גם בשל מידע שמסר הלקוח עצמו. כך למשל, מידע באשר לשנות הלימוד של הלקוח עלול לשעתק הפליה הנוגעת לקבוצות מיעוט שונות, כגון אוכלוסיות הערבים והחרדים, שמבחינה היסטורית ממעטים לרכוש השכלה גבוהה, ולהוביל להפליה אסורה מטעמי לאום או השתייכות דתית.²⁰⁷ גם מידע אלטרנטיבי שאינו פיננסי, המשוקלל לתוך מודל החיתום של המלווים, עלול להוביל להפליה אסורה. ההשלכות המפלות של שימוש בטכניקות המבוססות על בינה מלאכותית שמשקללות נתוני עתק תועדו במגוון הקשרים: אמזון הפסיקה להשתמש באלגוריתם למיון מועמדים לעבודה משום שגילתה כי הוא מפלה לרעה נשים;²⁰⁸ גוגל הצהירה כי תיקנה את מנגנון השלמת החיפוש האלגוריתמי שלה שהתגלה כמפלה יהודים;²⁰⁹ טכנולוגיות זיהוי הפנים של מייקרוסופט ו־IBM תועדו כמפלות על בסיס גזע ומין.²¹⁰ בהקשר של שימוש בעיבוד מידע אלגוריתמי בתחום האשראי הצרכני נטען, למשל, כי אפליקציית האשראי של חברת אפל, Apple Pay App, קבעה מסגרות אשראי נמוכות יותר לנשים לעומת גברים.²¹¹ אומנם טענות אלו נבדקו ונחקרו בידי האגף לשירותים פיננסיים במדינת ניו יורק, ה־New York State Department of Financial Services, אשר מצא כי לא נעשתה הפליה מכוונת על בסיס מגדר וגם לא נגרמה הפליה בלתי־מכוונת על בסיס מגדר.²¹² עם זאת אין להתעלם מן העובדה, שעם חשיפת התלונות על הפליה והעמקת הביקורת הציבורית נגד האפליקציה, חברת אפל תיקנה נקודתית את מסגרות האשראי של הנשים שטענו להפליה, והשוותה את מסגרות האשראי שלהן לאלו של בני זוגן.²¹³

- 207 נוהאד עלי ורימאא דעאס השכלה גבוהה בקרב המיעוט הערבי בישראל: ייצוג, מיפוי, חסמים ואתגרים 14 (2018); גלעד מלאך ולי כהנר שנתון החברה החרדית פרק ב (2020).
- 208 Jeffrey Dastin, *Amazon Scraps Secret AI Recruiting Tool that Showed Bias Against Women*, REUTERS (Oct. 11, 2018), <https://www.reuters.com/article/us-amazon-com-jobs-automation-insight/amazon-scraps-secret-ai-recruiting-tool-that-showed-bias-against-women-idUSKCN1MK08G>.
- 209 Samuel Gibbs, *Google Alters Search Automated Complete to Remove "Are All Jews Evil" Suggestion* (Dec. 5, 2018), THE GUARDIAN, <https://www.theguardian.com/technology/2016/dec/05/google-alters-search-autocomplete-remove-are-jews-evil-suggestion>.
- 210 Joy Buolamwin & Timnit Gebru, *Gender Shades: Intersectional Accuracy Disparities in Commercial Gender Classification*, in PROCEEDINGS OF MACHINE LEARNING RESEARCH 81:1-15 (Conference on Fairness, Accountability and Transparency, New York University, 2018) <http://proceedings.mlr.press/v81/buolamwini18a/buolamwini18a.pdf>.
- 211 Will Knight, *The Apple Card Didn't "See" Gender – and That's the Problem*, WIRED (Nov. 19, 2019), <https://www.wired.com/story/the-apple-card-didnt-see-gender-and-thats-the-problem>.
- 212 New York State Department of Financial Services, לעיל ה"ש 177.
- 213 Neil Vigdor, *Apple Card Investigated After Gender Discrimination Complaints*, N.Y. TIMES (Nov. 10, 2019), <https://www.nytimes.com/2019/11/10/business/Apple-credit->

מנגד יש לציין, כי מחקרים שבדקו הפליה בשוק המשכנתאות מצאו כי חברות פינטק, המעמידות אשראי על סמך שימוש בטכנולוגיות מתקדמות לעיבוד מידע, מצמצמות הפליה בנוגע לקבוצות מיעוט של אפרו־אמריקנים והיספאנים. אך עם זאת מחקרים אלו הבהירו, כי חברות אלו אינן מעלימות את ההפליה לחלוטין.²¹⁴

אין בידינו נתונים קונקרטיים המצביעים על הפליה בהעמדת אשראי צרכני על סמך עיבוד מידע אלטרנטיבי בישראל. אולם ניתן לשער כי הפליה בהקשר זה עלולה להתקיים, ולפיכך הנושא ראוי להיבחן. בפרט יש להדגיש, כי להבדיל מתהליך פיתוח של מודלים לדירוג אשראי בידי לשכות האשראי, הכפוף לביקורת ולפיקוח קפדניים מצד הרגולטור,²¹⁵ פיתוח מודלים פנימיים לחיתום אשראי בידי המלווים השונים אינו תמיד מפוקח.²¹⁶ זאת ועוד, בעוד שטיב המידע הפיננסי הגולמי המוזרם למאגר הלאומי והמשמש את לשכות האשראי בבניית המודלים שלהן מנוהל ומפוקח בידי בנק ישראל,²¹⁷ אין כל פיקוח על טיב המידע האלטרנטיבי הנאסף בידי המלווים השונים לצורך פיתוח המודלים הפנימיים שלהם. כמו כן, בעוד שללקוח יש אפשרות בקרה על טיב המידע המצוי עליו במאגר המידע (באמצעות הגשת בקשה לקבלת דוח ריכוז נתונים),²¹⁸ אין לו אפשרות לעשות כן בנוגע למידע המצוי בידי המלווים. בעקבות זאת, אלגוריתמים המבוססים על למידת מכונה יכולים ללמוד להשתמש בפרטי מידע מסוימים שאינם מפלים כאינדיקציה לקריטריונים מפלים.²¹⁹ בעיה

זו מכונה בספרות Proxy Discrimination.²²⁰

כך למשל, באמצעות מידע על המיקוד של הלקוח, האלגוריתם יכול ללמוד אם מדובר בלקוח מקבוצת מיעוט אתנית שנוטה להתגורר באזורים מסוימים.²²¹ בדומה, מידע על המוסד להשכלה גבוהה שבו למד הלקוח עשוי לשעתק הפליה על בסיס גזע, אם מבחינה היסטורית מדובר במוסד להשכלה גבוהה שנהגו ללמוד בו בני מיעוטים.²²² לחלופין, דירוג אשראי מסוים עלול להפלות מיעוטים אם הוא מחשב את סיכון האשראי של הלקוח על סמך היסטוריית תשלומי משכנתה בלבד, ככל שמדובר באוכלוסיות מיעוטים שנוטות לשכור נכסים ולא

.card-investigation.html

Daniel Shoag, *The Impact of Fintech on Discrimination in Mortgage Lending* (2021), 214 available at https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3840529; Bartlett et

al, להלן ה"ש 18.

215 לעיל בפרק א.1.

216 ראו להלן בפרק ד.3 באשר למלווים חוץ־בנקאיים.

217 ראו להלן בפרק א.1.

218 שם.

Dominique Williams, *Is the Fintech Era Uprooting Decades Long Discriminatory Lending Practices?*, 23 TUL. J. TECH. & INTELL. PROP. 159, 174-75 (2021) 219

Anya Prince & Daniel Schwartz, *Proxy Discrimination in the Age of Artificial Intelligence*, 105 IOWA L. REV. 1257 (2019) 220

Rose Eveleth, *Credit Scores Could Soon Get Even Creepier and More Biased*, VICE (Jun, 13, 2019), <https://www.vice.com/en/article/zmpgp9/credit-scores-could-soon-get-even-creepier-and-more-biased> 221

222 שם.

לרכוש בעלות בהם מטעמים תרבותיים, שאינם קשורים למסוגלות פיננסית.²²³ בדומה לכך, אם דירוג אשראי מסוים משתמש בנתוני השכלה כאינדיקציה למסוגלות פיננסית, הרי הוא עלול להפלות לרעה מיעוטים שסובלים מהיעדר גישה מספקת להשכלה.²²⁴

נתונים שפורסמו במסגרת מחקר שערכה חטיבת המחקר בבנק ישראל בשנת 2019, אשר בחן ראיות לשונות בתמחור משכנתאות בישראל, מדגימים את החשש ל-Proxy Discrimination.²²⁵ במחקר זה נבחנו 88,914 משכנתאות שהועמדו למשקי בית בישראל בין ה'1 בינואר 2010 ל'31 בדצמבר 2013. בחינת התפלגות שיעוריה של ריבית המשכנתה הריאלית הממוצעת לפי המרחק מתל אביב הצביעה על כך, שתושבי הפריפריה משלמים ריבית גבוהה משמעותית על הלוואות משכנתה לעומת תושבי מרכז הארץ, והפער אף גדל ככל שמדובר בשכונות מוחלשות בפריפריה מול שכונות מבוססות במרכז.²²⁶ הסיבה לגביית הריבית הגבוהה לא נבעה בהכרח מתכונותיהם האישיות של המלווים, אלא מנסיבות אחרות, כגון קושי לממש משכנתאות בפריפריה או עלויות מימוש יקרות יותר. ככלל, קיומה של ריבית גבוהה יותר הוא נתון ניטרלי המשקף סיכון גבוה יותר, ולכן הוא עלול לפגוע בדירוג האשראי של הלקוח. עולה מכך שככל שתושבי הפריפריה כקבוצה מאופיינים כבעלי סיכון גבוה יותר רק בשל עצם הריבית הגבוהה שנגבתה מהם, הרי שימוש בפרמטר של גובה הריבית בבניית מודל חיתום אשראי עלול להוביל להפליה אסורה על בסיס מקום מגורים.²²⁷

לבסוף, מלבד טיב המידע המשמש להפקת מודל החיתום, גם האופן שבו המידע ממוין – הקטגוריות ותתי-קטגוריות השונות המיינות את המידע הגולמי – עשוי להוביל לתוצאות מפלות. השימוש בטכנולוגיות מתקדמות של למידת מכונה לשם פיתוח המודל מאפשר לבצע קטגוריזציה פרטיקולרית מאוד בנוגע למידע, מה שמאפשר להפיק תמחור פרסונלי (personalized pricing) של ההלוואה. משמעות הדבר היא, שההבדלים הקיימים בין לקוחות מקבלים משקל גדול מאוד במסגרת מודלים לחיתום המבוססים על טכנולוגיות מתקדמות של למידת מכונה.²²⁸ בפרט, השימוש בלמידת מכונה במסגרת מודלים לדירוג אשראי מוביל לשונות גדולה יותר בין לווים שונים, וכפועל יוצא לשונות גדולה יותר מבחינת סיכון האשראי הפוטנציאלי שלהם. כך, לווה מסוים שהיה עשוי להיכלל בקבוצת הלא-מסוכנים בעולם שבו ישנה קטגוריזציה בסיסית יותר (למשל, כאשר טכניקת בניית המודל מבוססת על רגרסיה ליניארית ומספר קבוצות הסיכון הוא נמוך), עלול למצוא את עצמו תחת קבוצה בעלת סיכון אשראי נמוך בעולם שבו יש שימוש בלמידת מכונה וישנן קבוצות רבות מאוד של סיכון אשראי.²²⁹ מבחינה כלכלית, הבחנה שכזו בין לקוחות היא רצויה. היא מאפשרת לתמחר את ההלוואה לכל לקוח בצורה מדויקת בהתאם לרמת הסיכון שלו, להפחית סבסוד צולב בין לווים ולהפחית את הריבית ללווה איכותי יותר ממשנהו. בהנחה שאין אינדיקציה

223 Gillis, לעיל ה"ש 18, בעמ' 43.

224 שם, בעמ' 21.

225 נטליה פרסמן וניצן צור-אילן האם מקום הנכס הנרכש משפיע על תמחור המשכנתה – ראיות לשונות בתמחור משכנתאות בישראל (בנק ישראל – חטיבת המחקר, דצמבר 2019).

226 שם, בעמ' 9.

227 שם, בעמ' 18.

228 שם, בעמ' 41.

229 שם, בעמ' 41-42.

ברורה לקיומם של שיקולים מפלים באלגוריתם, מדובר בהבחנה כלכלית מותרת.²³⁰ ואולם אם שונות זו נובעת משקלול מידע העשוי לשעתק הפליה היסטורית (דוגמת ריביות על משכנתה שנדרו לעיל) או משקלול מידע אלטרנטיבי העשוי לשמש אינדיקטור לקריטריון מפלה (דוגמת מיקוד שנדון לעיל), הרי היא יכולה לגרום להפליה אסורה.

4. הפליה שנובעת משיטת ניתוח המידע

הסיבה השנייה שבגינה מודלים אלגוריתמיים לחיתום אשראי עשויים להוביל לתוצאות מפלות קשורה לשיטה שבה המידע מנותח.²³¹ כיום הנטייה היא להתבסס על טכנולוגיות של למידת מכונה שמתאימות לעיבוד כמויות גדולות של מידע גולמי.²³² אולם שיטות שונות של למידת מכונה משפיעות בצורה שונה על החשש להפליה בלתי-מכוונת. כך, למידה מבוקרת עשויה להגדיל את החשש להפליה משום שהיא מבוססת ברובה על ניתוח "מידע היסטורי מסומן" (labeled data) בנוגע ללקוחות עבר וללקוחות קיימים של המלווה, כדי ליצר ניבוי פרטיקולרי ללווה המסוים.²³³

נסביר עניין זה בדוגמה הבאה. נניח כי משתנה המטרה (target variable) של האלגוריתם יהיה "כושר פירעון", כלומר מטרת המתכנתים היא ללמד את האלגוריתם לנבא כושר פירעון של לקוחות חדשים. לשם כך המלווה מסתמך על מידע קודם המצוי בחזקתו, המצביע על כושר הפירעון של לקוחות קודמים (אילו לקוחות עמדו בעבר בפירעון ההלוואה ואילו לקוחות כשלו בעבר בפירעון). בהמשך המלווה מסמן את פרטי המידע השייכים ללקוחות בעלי כושר פירעון גבוה ואת פרטי המידע השייכים ללקוחות בעלי כושר פירעון נמוך. על בסיס מידע זה האלגוריתם לומד לסווג את הקריטריונים המשפיעים על משתנה המטרה (כך למשל, השאלה באיזו מידה יציבות תעסוקתית משפיעה על כושר הפירעון). במילים אחרות, מידע היסטורי מסומן שימש לפיתוח מודל החיתום. הבעיה היא, כמוסבר לעיל, שהמידע ההיסטורי המסומן עלול לשמש אינדיקטור לתבחינים אסורים (כך למשל, בנוגע לשאלה אם יציבות תעסוקתית מאפיינת אוכלוסייה מבוגרת כקבוצה). ואם אכן כך, הרי המודל ישעתק את ההפליה המובנית במידע (כך למשל, הפליה מטעמי גיל).

עם זאת ישנן דרכים שונות למזער את החשש להפליה בלמידה מבוקרת. אפשרות אחת היא לנטר את המידע הגולמי בטרם ישמש ללמידה כך שתובטח הוגנות.²³⁴ השיטה הטיפוסית בהקשר זה מבוססת על ניתוק הקורלציה שבין פרטי המידע הגולמי לתבחין

230 ראו לעיל בפרק ג.1.

231 Michael Veale & Reuben Binns, *Fairer Machine Learning in the Real World: Mitigating Discrimination Without Collecting Sensitive Data*, BIG DATA & SOCIETY 1 (2017) ("Model choice itself can be political. Neural networks or random forests are more amenable to capturing synergy between variables than linear regression. Use of regression might .omit important contextual variance, for example")

232 ראו לעיל בפרק ב.

233 FinRegLab, לעיל ה"ש 144, בעמ' 56.

234 Nikita Kozodoi, Johannes Jacob & Stefan Lessmann, *Fairness in Credit Scoring: Assessment, Implementation and Profit Implications*, ARXIV.ORG (2021), <https://arxiv.org/pdf/2103.01907.pdf>

האסור.²³⁵ ככל שלמידת המכונה מתבצעת על מידע הוגן, ההנחה היא שגם שלבי פיתוח המודל האלגוריתמי יהיו הוגנים.²³⁶ לחלופין, במקום לנטר את המידע מראש, ניתן להתערב בתהליך הלמידה ולהגבילו תוך כדי התרחשותו, תוך ביצוע התאמות המבטיחות שהקריטריון המסווג את המידע אינו מפלה.²³⁷ בעוד ששיטה זו נחשבת ליעילה מאוד, המגבלה שלה טמונה בכך שהיא בוחנת את הוגנות הקריטריון המסווג באשר לתבחין אסור מסוים בלבד (כגון מגדר או גזע).²³⁸ לבסוף, ניתן לצמצם הפליה גם בדיעבד, באמצעות שינוי הקריטריון המסווג שאותו למד האלגוריתם או באמצעות עדכון הניבוי שלו, אם נמצא כי הוא מבוסס על תבחינים אסורים.²³⁹

למידה לא-מבוקרת, לעומת זאת, המתבצעת על היקפים נרחבים של מידע לא-מסומן (unlabeled data) דוגמת מידע המצוי במאגרים פומביים ברשת, היא בעלת יתרונות בצמצום הפליה בלתי-מכוונת. הסיבה לכך היא שלמידה לא-מבוקרת אינה כוללת מידע המסומן בהתאם למשתנה מטרה (כגון השאלה אלו לקוחות כשלו או עמדו בעבר בפירעון ההלוואה), אלא היא מבוססת על מידע מגוון מאוד.²⁴⁰ כלומר, מודלים ללמידה לא-מבוקרת אינם מיועדים לנבא במישרין את הסיכוי לכשל אשראי, אלא מטרתם היא למצוא קריטריונים שמשותפים לקבוצת הלקוחות שבבסיס המידע. קריטריונים אלו ישמשו בהמשך את המודלים ללמידה מבוקרת. כך למשל, למידה לא-מבוקרת עשויה למצוא כי לקוחות שרוכשים מצרכים בתדירות מסוימת באינטרנט הם גם בעלי יציבות תעסוקתית. קריטריונים אלו יוכלו לשמש לאחר מכן את המודל המבוקר כדי לבדוק אם ובאיזו מידה הם משפיעים על הסיכוי לכשל אשראי.²⁴¹ עם זאת כדי להבטיח הוגנות וכדי למנוע הפליה, חשוב שתוצרי המודלים המבוססים על למידה לא-מבוקרת ייבחנו בידי אנשי הטכנולוגיה בדיעבד.

ד. חיתום אשראי אלגוריתמי: המסגרת המשפטית-רגולטורית

כפי שהראינו בפרק הקודם, חיתום אשראי המבוסס על שימוש במודלים אלגוריתמיים עלול להוביל להפליה, להדרת אשראי ולפגיעה באוכלוסיות מוחלשות. בפרק זה נבחן כיצד החוק והרגולציה מתמודדים עם בעיה זו. ככלל, אפשר להצביע על ארבעה סוגי אסדרה

Flavio Calmon et al., *Optimized Preprocessing for Discrimination Prevention*, in 235
ADVANCES IN NEURAL INFORMATION PROCESSING SYSTEMS 30, 3992 (I. Guyon et al. eds,
2017), <https://papers.nips.cc/paper/2017>

Barocas & Selbst, *לעיל ה"ש 16*. 236

Muhammad Bilal Zefar et al., *Fairness Beyond Disparate Treatment & Disparate 237*
Impact: Learning Classification Without Disparate Mistreatment 1171 (International
Conference on World Wide Web, 2017)

Barocas & Selbst, *לעיל ה"ש 16*. 238

Kozodoi, *לעיל ה"ש 234*. 239

Tao Zhang et al., *Fairness in Semi-Supervised Learning: Unlabeled Data Help to 240*
Reduce Discrimination, 14 J. LATEX CLASS FILES 1 (2015)

FinRegLab, *לעיל ה"ש 144*, בעמ' 58. 241

האוסרים על חיתום אלגוריתמי באופן העלול להביא לידי הפליה פסולה או קיפוח לקוחות מחלשים:

- (1) חקיקה כללית האוסרת על הפליה;
 - (2) חקיקה או רגולציה המגבילה את השימוש בבינה מלאכותית;
 - (3) הוראות הרגולטורים הפיננסיים באשר לשימוש במודלים אלגוריתמיים;
 - (4) חקיקה או רגולציה בנוגע למתן אשראי צרכני.
- כל אחת מקטגוריות אלה תידון להלן בנפרד.

1. חקיקה כללית האוסרת על הפליה

חוק איסור הפליה במוצרים, בשירותים ובכניסה למקומות בידור ולמקומות ציבוריים, התשס"א-2000 (להלן: חוק איסור הפליה) אוסר על הפליה באספקת מוצרים ושירותים ציבוריים. החוק חל גם על נותני שירותים פיננסיים – בתחום הבנקאות, הביטוח ומתן האשראי.²⁴² החוק אוסר להפלות במתן השירות מחמת גזע, דת או קבוצה דתית, לאום, ארץ מוצא, מין, נטייה מינית, השקפה, השתייכות מפלגתית, גיל, מעמד אישי, הורות, מקום מגורים ומחמת לבישת מדי כוחות הביטחון וההצלה או ענידת סמליהם.²⁴³ הפרת הוראות החוק מהווה עוולה אזרחית ועבירה פלילית.²⁴⁴

רקע פיננסי או מצב כלכלי אינם נמנים עם עילות ההפליה שבחוק. יותר מכך, החוק מסייג וקובע כי אין מכירים בהפליה כאשר "הדבר מתחייב מאופיו או ממהותו" של המוצר או השירות.²⁴⁵ הבחנה בין לקוחות לפי רמת מוסר התשלומים או כושר הפירעון בעת חיתום אשראי מתחייבת מעצם מהותו של שירות האשראי, ולכן היא נכנסת לגדרי החריג האמור. לכן, כל עוד ההבחנה בין לקוחות נעשית על סמך שיקול זה אין מדובר בהפליה פסולה.²⁴⁶

242 ראו לעיל ה"ש 6 ואת את הגדרת המונחים "שירות ציבורי" ו"שירותים פיננסיים" בס' 2 לחוק.
 243 שם, בס' 3(א) ו-1(א) לחוק. החוק מוסיף וקובע, כי סירוב לספק מוצר או שירות לאחר שמציע המוצר או השירות "בירר" פרטים הנוגעים לעילות ההפליה האמורות מקים חזקת הפליה, כל עוד לא הוכח אחרת (ראו שם). עם זאת ההנחה היא שהמערכות האלגוריתמיות – להבדיל מחיתום אנושי – אינן מבררות פרטים שכאלה, ומכאן שחזקת ההפליה אינה קמה בעניינן.
 244 שם, בס' 5 ו-9 לחוק, בהתאמה.

245 שם, בס' 3(ד) לחוק. חריג זה זכה לפרשנות רחבה בהקשר דומה של חיתום לביטוח, ב"ע"ע (ארצי) 26328-09-14 הראל חברה לביטוח בע"מ נ' אשבל, פס' 70-93 לפסק דינו של סגן הנשיאה איטח (נבו 26.4.2016). באותו מקרה נטען, כי חברות הביטוח נוהגות לזכות מבוטחות (נשים) המגיעות לגיל פרישה בגמלה חודשית נמוכה מזו שמקבל מבוטח (גבר) בעל נתונים זהים, ככיוול לאור תוחלת החיים הארוכה יותר של נשים. אך במקביל הן גובות מנשים פרמיה בגין רכיב הסיכון בשיעור זהה לשיעור הנגבה מגברים, אף ששיעורי התמותה שלהן נמוכים בהרבה. בית הדין הארצי לעבודה סירב להכיר בהפליה. הוא קבע כי ההבחנה בין גברים לנשים ברכיב הגמלה לא נשענה על תפיסות סטראוטיפיות מגדריות אלא נבעה מטעמים ענייניים, טעמים שהצדיקו חריגה מעקרון התעריף האחיד ברכיב הגמלה אך שמירה על עקרון התעריף האחיד ברכיב הסיכון.

246 ראו לעיל בפרק ג.1.

247. חוק איסור הפליה שימש בסיס לתביעות לא-מעטות נגד בנקים בהקשרים שונים.²⁴⁷
 עם זאת לא עלה בידינו למצוא פסיקה שבה נדונה טענה להפליה בעצם חיתום האשראי.²⁴⁸
 האיסור על בנקים להפלות בין לקוחות נובע גם ממעמד המעין-ציבורי, כפי שהוכר
 בפסיקת בית המשפט העליון,²⁴⁹ ומן הדואליות הנורמטיבית החלה עליהם מכוח מעמד
 זה.²⁵⁰ לפי גישה זו הבנקים כפופים לחובות מסוימות החלות על גופים ציבוריים, ואיסור
 ההפליה בכללם.²⁵¹ הכפיפות לנורמות החלות על גופים ציבוריים עשויה להשפיע גם על
 עוצמתן. כך, חובת השוויון עוצמתית יותר במשפט המנהלי מאשר במשפט הפרטי,²⁵² שבו
 ניתן משקל גדול יותר לחופש ההתקשרות ולאוטונומיית הפרט.²⁵³ גישה זו מטילה על
 הבנקים – כגופים מעין-ציבוריים – נורמת התנהגות מחמירה יותר מאשר זו המוטלת על
 עוסק פרטי "רגיל", ומחילה את איסור ההפליה גם בנסיבות שבהן עוסק פרטי "רגיל" אינו
 כפוף לו. גישה זו עשויה לסייע בין השאר למניעת הפליה בלתי-מכוונת, הנגרמת בעקיפין
 על אף שימוש בתבחינים חוקיים בלבד.²⁵⁴

מקור נורמטיבי נוסף האוסר על בנקים להפלות לקוחות הוא חובת האמון הבנקאית.
 חובת האמון היא החובה המחמירה ביותר בתחום המשפט האזרחי. חובה זו מטילה על
 הבנקים סטנדרט התנהגות גבוה מאוד כלפי לקוחותיהם. מכוח חובת האמון עליהם להגן

247 ראו למשל: ת"צ (מחוזי י-ם) 59462-01-16 אבו פריח נ' הבנק הבינלאומי הראשון לישראל בע"מ (נבו 24.12.2017), שם נדחתה בקשה לאישור תובענה ייצוגית בנושא הפליית האוכלוסייה הערבית בנגישות לשירותים בנקאיים בגין אי-פתיחת סניפים ביישובים ערביים; בת"צ (מחוזי ת"א) 26151-02-16 טמיר נ' בנק הפועלים בע"מ (נבו 26.9.2019). נדחתה בקשה לאישור תובענה ייצוגית בנושא הפליה מחמת גיל, בטענה שהבנק מאפשר רק לסטודנטים צעירים להצטרף ל"חשבון סטודנט" המזכה בהטבות.

248 חריג מסוים לכך הוא ת"צ (מחוזי ת"א) 27197-12-19 אינדיג נ' בנק הפועלים בע"מ (נבו 25.11.2021). הוגשה בקשה לאישור תובענה ייצוגית בטענה שהבנק מסרב לתת הלוואות משכנתה לנכסים הנמצאים מעבר לקו הירוק, ובכך מפלה את הלוחים על בסיס מקום מגוריהם. טרם ניתנה החלטה בתיק. הדיווח של הממונה על השיתוף בנתוני אשראי לכנסת על תלונות ציבור שהוגשו לו מציין, כי הוגשו לממונה גם תלונות בנושא אי-קבלת אשראי. עם זאת ככל שמדובר בתאגידים בנקאיים, הטיפול בתלונות אלה הוא בסמכות המפקח על הבנקים. התלונות מועברות לטיפול בהתאם לנוהל עבודה פנימי בין הממונה לבין המפקח על הבנקים. ראו דיווח לוועדת הכלכלה 2021, לעיל ה"ש 33, בעמ' 17-18. לא הצלחנו למצוא מידע נוסף על תלונות אלה.

249 לתיאור גישה זו ולביקורת עליה, ראו: PLATO-SHINAR, לעיל ה"ש 167, בעמ' 40-44.

250 על הדואליות הנורמטיבית שחלה על תאגידים מתחום המשפט הפרטי, ראו דפנה ברק-ארוז משפט מינהלי כרך ג – משפט מינהלי כלכלי 463 ואילך (2013) (להלן: ברק-ארוז משפט מינהלי כרך ג); אסף הראל גופים ונושאי משרה דו מהותיים 193-195 (מהדורה שנייה 2019).
 251 על איסור ההפליה במשפט המנהלי, ראו דפנה ברק-ארוז משפט מינהלי כרך ב 673-722 (2010) (להלן: ברק-ארוז משפט מינהלי כרך ב).

252 ברק-ארוז משפט מינהלי כרך ג, לעיל ה"ש 250, בעמ' 466-467.

253 הראל, לעיל ה"ש 250, בעמ' 373-377.

254 ראו על כך בנושא איסור הפליה במשפט המנהלי אצל ברק-ארוז משפט מינהלי כרך ב, לעיל ה"ש 251, בעמ' 699.

על אינטרס הלקוח ולהעדיפו על כל אינטרס אחר, אף על האינטרס האישי של הבנק.²⁵⁵ מובן כי הפליה בין לקוחות אינה עולה בקנה אחד עם חובת האמון.

2. חקיקה או רגולציה כללית המגבילה את השימוש בבינה מלאכותית

אין בישראל חקיקה כללית המגבילה את השימוש בבינה מלאכותית במטרה למנוע פגיעה באינטרסים ובזכויות אדם מוגנות, ובכלל זה הפליה. עם זאת יוזמה מעניינת של המיזם הלאומי למערכות נבונות הייתה הקמתה של ועדת משנה לבחינת ההיבטים האתיים והרגולטוריים של בינה מלאכותית. בשנת 2019 פרסמה הוועדה דוח, אשר המליץ על העקרונות האתיים שיש להחיל על פעולות פיתוח ושימוש בטכנולוגיות בינה מלאכותית, ואשר הציג את האפשרויות השונות להסדרת התחום.²⁵⁶

הוועדה הצביעה על כמה עקרונות אתיים מרכזיים שאמורים לעמוד בבסיס השימוש בבינה מלאכותית. העיקרון הראשון הוא "הוגנות", המוגדר כ"חתיירה לשוויון מהותי, מניעת הטיות (במידע בתהליך ובתוצר), מניעת הפליה, הימנעות מהגדלת פערים חברתיים כלכליים והשכלתיים".²⁵⁷ עיקרון נוסף הוא "אחריותיות", הכולל שלושה רכיבים אלה: חלוקת האחריות בין הגורמים המעורבים בתהליך; שקיפות של המידע על התהליך עצמו ועל דרך קבלת ההחלטה; הסכרתיות – היכולת להסביר את תהליך קבלת ההחלטה של המערכת עבור הגורמים השונים העשויים להיות מושפעים ממנה.²⁵⁸ לדרישת ההסכרתיות יש חשיבות רבה בהקשר של מניעת הפליה, משום שלעיתים אופן בניית המודל הוא המביא לתוצאות המפלגות, אף אם הנתונים המוזנים למודל אינם מפלים בפני עצמם.²⁵⁹ עיקרון אחר הוא כיבוד זכויות אדם, הכוללות, בין השאר, את הזכות לפרטיות ואוטונומיית הפרט.²⁶⁰ הוועדה המליצה לראות בכל העוסקים בבינה מלאכותית אחראים לפעול בצורה חוקית ואתית.²⁶¹ כמו כן היא המליצה, כי הרשויות הרגולטוריות האחראיות על משאבי מידע כחלק מתחום הליבה שלהן יידרשו לבחון בהתאם לעקרונות האתיים האמורים, אם יש צורך בהתאמת המסגרת הרגולטורית בנוגע לשימוש בבינה מלאכותית בתחומי הפעילות המוסדרים על ידן.²⁶²

255 על חובת האמון הבנקאית, ראו: רות פלאטו־שנער "הרהורים בנושא גבולותיה הראויים של חובת האמון הבנקאית – הבנק כאפוטרופוס של הלקוח?" חובות אמון בדין הישראלי (רות פלאטו־שנער ויהושע שגב עורכים 2016); רות פלאטו־שנער ואביבה גבע "חובת האמון הבנקאית – המודל הישראלי" משפט ועסקים יא 393, 395-397 (2009).

256 ועדת משנה של המיזם הלאומי למערכות נבונות בנושא אתיקה ורגולציה של בינה מלאכותית דין וחשבון (נובמבר 2019) https://www.gov.il/he/departments/news/artificial_intelligence (להלן: דוח ועדת משנה של המיזם הלאומי למערכות נבונות).

257 שם, בעמ' 13; ראו גם שם, בעמ' 15.

258 שם, בעמ' 13, 16-17.

259 ראו לעיל בפרק ג.4.

260 דוח ועדת משנה של המיזם הלאומי למערכות נבונות, לעיל ה"ש 256, בעמ' 17-20.

261 שם, בעמ' 22.

262 שם, בעמ' 34.

גם במדינות אחרות ניכרת מודעות לצורך בהסדרת ההיבטים האתיים של השימוש בבינה מלאכותית, במטרה להגן על זכויות האדם. כך למשל, בארצות הברית פרסמה נציבות הסחר הפדרלית (Federal Trade Commission – FTC) אזהרה, שלפיה כלים של בינה מלאכותית שמשקפים הטיות מגדריות וגזעיות עלולים להפר את חוקי הגנת הצרכן.²⁶³

גישה אחרת ננקטה לאחרונה באירופה עם פרסום טיוטת הרגולציה על שימוש בבינה מלאכותית.²⁶⁴ מטרתה העיקרית של הטיוטה היא לשמור על זכויות האדם המוגנות בעת שימוש בבינה מלאכותית, ובכלל זה למנוע הפליה.²⁶⁵ הטיוטה מאופיינת בגישה המבוססת על סיכונים, והיא מציבה דרישות מחמירות במיוחד באשר למערכות היוצרות סיכון גבוה לזכויות אדם, ובכלל זה מערכות לדירוג אשראי.²⁶⁶ מערכות בינה מלאכותית בסיכון גבוה יידרשו לקיים שורה של דרישות כגון אלה: הקמת מערך ניהול סיכונים ייעודי; הקפדה על איכות גבוהה של מסדי נתונים; תיעוד ושמירה של חומרים כדי לאפשר שחזור של התוצאות; פיקוח אנושי ראוי על כל שלבי עבודת המערכות; וכן שקיפות מסוימת של המערכות כדי לאפשר לפרש את התוצאות המתקבלות מעיבוד המידע בצורה ראויה.²⁶⁷ דרישות אלו עשויות למנוע מראש שימוש ועיבוד של מידע באופן מפלה, וכן לאפשר בקרה בדיעבד אחר אופן ביצוע פעולות אלה. עם זאת, מנגנונים חשובים למניעת הפליה, כגון הסברות, לא נכללו בטיוטה, מתוך הבנה שהם מעוגנים ברגולציה האירופית בנושא הגנת המידע, אשר תידון להלן.²⁶⁸

אפשר למצוא התייחסות לעיבוד אוטומטי של מידע גם ברגולציה האירופית בנושא הגנת המידע – General Data Protection Regulation (GDPR).²⁶⁹ המטרה של רגולציה זו היא

-
- Elisa Jillson, *Aiming for Truth, Fairness, and Equity in Your Company's Use of AI*, 263
 FEDERAL TRADE COMMISSION (Apr. 19, 2021), <https://www.ftc.gov/news-events/blogs/business-blog/2021/04/aiming-truth-fairness-equity-your-companys-use-ai>, להרחבה,
 ראו: Allen B. Bachman, *FTC Issues New Guidance, Warning That Bias in Artificial Intelligence Could Create Potential Liability for Enforcement Actions*, 9 (221) NAT. L. REV. (Aug. 9, 2021), <https://www.natlawreview.com/article/ftc-issues-new-guidance-warning-bias-artificial-intelligence-could-create-potential>.
- Proposal for a regulation of the European parliament and of the council laying down 264
 harmonised rules on artificial intelligence (artificial intelligence act) and amending
 certain union legislative acts COM/2021/206 final (Apr. 21, 2021), https://eur-lex.europa.eu/resource.html?uri=cellar:e0649735-a372-11eb-9585-01aa75ed71a1.0001.02/DOC_1&format=PDF.
- 265 ראו למשל שם, בס' 1.2, 3.5 לדברי ההסבר, וכן בס' 15, 17, 35-37, 39, 44 למבוא.
 266 שם, בס' 6 ובנספח 3.
 267 שם, בס' 8-15; ראו גם ס' 16-22.
 268 Katja Langerbucher, *AI Credit Scoring and Evaluation of Creditworthiness – A Test Case for the EU Proposal for an AI Act*, Ch. 3 (ESCB Legal Conference 2021, 2022)
 269 Regulation (EU) 2016/679 of the European Parliament and of the Council of 27 April 2016 on the Protection of Natural Persons with Regard to the Processing of Personal Data and on the Free Movement of Such Data and Repealing Directive 95/46/EC

הגנת הפרטיות באמצעות מתן שליטה לאנשים על המידע האישי שנשמר על אודותם בקרב גופים עסקיים וממשלתיים, ובכלל זה על עיבוד המידע. עם זאת חלק מהקביעות שברגולציה רלוונטיות גם לדירוגי אשראי ולחשש מפני הפליה שהם עלולים ליצור.

כך, סעיף 9 לרגולציה אוסר לעבד מידע אישי הכולל נתונים מהסוגים הבאים: גזע או מוצא אתני, דעות פוליטיות, אמונה דתית או פילוסופית, חברות בארגון סחר, מידע גנטי או ביומטרי, מידע בריאותי ומידע על פעילות או על נטיות מיניות. לסעיף זה חשיבות רבה לשם מניעת הפליה. סעיף 22 לרגולציה מכיר בזכות שלא להיות כפוף להחלטה מהותית המבוססת על עיבוד אוטומטי של מידע ללא מעורבות אנושית. הסעיף מכיר בזכותו של הפרט למעורבות אנושית בתהליך האוטומטי, להביע את דעתו האישית ולתקוף את ההחלטה האוטומטית.²⁷⁰ מדובר בזכויות קריטיות להבטחת זכויותיו של הפרט, לרבות זכותו שלא להיות מופלה לרעה.

שקיפות היא תנאי הכרחי לבקרה אפקטיבית ולאפשרות לזוהות מגמות מפלות בתהליכי עיבוד המידע האלגוריתמיים. לשם כך הרגולציה מעניקה לאדם שהמידע בעניינו זכות גישה למידע האישי ששימש בעניינו ולמידע מסוים בנוגע לאופן עיבוד המידע.²⁷¹

בנוגע לקבלת החלטות וליצירה אוטומטית של פרופילים, מעבד המידע נדרש ליידע את האדם שהמידע בעניינו על כך שמדובר בהליך אוטומטי, לספק לו מידע "בעל ערך" על ההיגיון שעליו מבוססת ההחלטה האוטומטית וכן להסביר לו את ההשלכות הצפויות של ההליך האוטומטי עבורו.²⁷² הרגולציה אינה מציבה דרישה מפורשת להסברות כאשר למודל האלגוריתמי, אך יש מי שסבורים שחובה זו מתבקשת מחובות אחרות הכלולות בה, כגון החובה לספק מידע בעל ערך.²⁷³

בישראל טרם נעשתה הסדרה כללית לעניין השימוש בכינה מלאכותית. בסעיף הבא נברוק אם חסר זה זכה להסדרה ייעודית של הרגולטורים הפיננסיים כלפי הגופים שעליהם הם מפקחים.

(General Data Protection Regulation), 2016 O.J. (L 119), <https://eur-lex.europa.eu/eli/reg/2016/679/oj> (להלן: "הרגולציה האירופית להגנת המידע" או "GDPR").

270 לניתוח הסעיף, ראו: Lilian Edwards & Michael Veale, *Slave to the Algorithm? Why a "Right to an Explanation" is Probably Not the Remedy You Are Looking For*, 16 DUKE L. & TECH. REV. 18, 44-51 (2017); Tal Z. Zarsky, *Incompatible: The GDPR in the Age of Big Data*, 47 SETON HALL L. REV. 995, 1015-18 (2018) זכות דומה עומדת ללקוח גם על פי הדין הישראלי, מכוח ס' 38 ו-56 לחוק נתוני אשראי.

271 ס' 13-15 לרגולציה האירופית להגנת המידע.

272 ס' 13(2)(f), 14(2)(g), 15(1)(h) לרגולציה האירופית להגנת המידע.

273 Margot E. Kaminski, *The Right to Explanation, Explained*, 34 BERKLEY TECH. L.J. 189 (2019) (להלן: *Rethinking*; Bryan Casey et al., *Explaining Machines: The GDPR's "Right to Explanation" Debate and the Rise of Explainable Machines: The GDPR's "Right to Explanation" Debate and the Rise of Explainable Machines*, 34 BERKELEY TECH. L.J. 143 (2019) *Algorithmic Audits in Enterprise*, Sandra Wachter et al., *Why a Right to Explanation of Automated Decision-Making Does Not Exist in the General Data Protection Regulation*, 7(2) INT'L DATA PRIVACY L. 76 (2017) ראו Edwards & Veale, לעיל ה"ש 270, שם.

3. הוראות הרגולטורים הפיננסיים באשר לשימוש במודלים אלגוריתמיים

עם התרחבות השימוש בכינה מלאכותית בידי גופים פיננסיים החלו רגולטורים פיננסיים ברחבי העולם לתת את דעתם לנושא. הגישה המאפיינת היא מתן מידע, המלצות והדרכה, להבריל מקביעת כללים מחייבים.

כך למשל, רשות הבנקאות האירופית פרסמה בחודש ינואר 2020 דוח על המגמות האחרונות בנוגע לנתוני עתק ולניתוח מתקדם של מידע בסקטור הבנקאי.²⁷⁴ מטרת הדוח הוגדרה כלימודית – לשתף את קבוצות העניין הרלוונטיות בידע, ובעיקר להבטיח שרגולטורים פיננסיים מעודכנים בהתפתחויות האחרונות בנוגע לשימושי כינה מלאכותית בתחום הפיננסי. הדוח מתייחס לארבעת האלמנטים הבאים, שמטרתם להבטיח את אמון הציבור במערכות הכינה המלאכותית, וקורא להקפיד על קיומם: אתיקה; הגינות ומניעת הטיות; הסברתיות בנוגע לאופן עיבוד המידע; יכולת מעקב ובקרה. בין השאר, הדוח ממליץ לבנקים להקים ועדת אתיקה כדי לתקף את השימוש בכינה מלאכותית וכדי לוודא שכללי האתיקה יישמרו.²⁷⁵ המוטיב האתי, החוזר לאורך כל הדוח, אמור להגן על הציבור מפני פרקטיקות פסולות העלולות להביא להפליה ולפגיעה באוכלוסיות המוחלשות.

בגרמניה פרסם בשנת 2021 הרגולטור הפיננסי, BaFin, מסמך עקרונות יסוד בנושא השימוש באלגוריתמים בתהליכי קבלת החלטות של מוסדות פיננסיים.²⁷⁶ עקרונות אלה מוגדרים כרעיונות ראשוניים לדרישות סף פיקוחיות במטרה ליצור בסיס לשיחות בנושא עם בעלי העניין.²⁷⁷ אחד מעקרונות היסוד במסמך הוא מניעת הטיות, הן כדי להבטיח את איכות ההחלטות והן כדי לשלול הפליה של קבוצות אוכלוסייה מסוימות. הרגולטור מזהיר בהקשר זה שהטיות עלולות להיגרם בשל מידע באיכות או בכמות לא-מספקת כאשר מאפיינים מסוימים אינם מובאים בחשבון או מקבלים משקל עודף ללא הצדקה, או כאשר תוצאות אלגוריתמיות נכונות מקבלות פרשנות שגויה.²⁷⁸ המסמך אוסר על שימוש בהבחנות האסורות

European Banking Authority, *EBA Report on Big Data and Advanced Analytics*, EBA 274 (Jan. 2020), available at https://www.eba.europa.eu/sites/default/documents/files/document_library/Final%20Report%20on%20Big%20Data%20and%20Advanced%20Analytics.pdf.

275 שם, בעמ' 35, 45. בכל הנוגע לאתיקה, הדוח מפנה ליוזמה אירופית כללית שאינה מוגבלת לתחום הפיננסי רווקא – הנחיות אתיות ללמידת מכונה בת סמכא, שפרסמה קבוצת המומחים ללמידת מכונה שהקימה הנציבות האירופית. ראו: High-Level Expert Group on Artificial Intelligence: *Ethics Guidelines for Trustworthy AI* (Apr. 2019), available at <https://digital-strategy.ec.europa.eu/en/library/ethics-guidelines-trustworthy-ai>.

Bundesanstalt für Finanzdienstleistungsaufsicht (BaFin), *Big Data and Artificial Intelligence: Principles for the Use of Algorithms in Decision-Making Processes*, BaFin (Jun. 15, 2021), available at https://www.bafin.de/SharedDocs/Downloads/EN/Aufsichtsrecht/dl_Prinzipienpapier_BDAI_en.html?sessionId=0D695116D0B9A809_cid503?nn=9866146. (להלן: BaFin).

277 שם, בעמ' 4, 5, 16.

278 שם, בעמ' 8.

על פי דין, וכן על שימוש בשיטת הפרוקסי העלולה להביא להפליה אף היא. בהמשך המסמך מפרט עקרונות ספציפיים ליישום עקרונות היסוד האמורים. כמה מהדרישות הן אלה: נדרש שהמודל יאפשר ליצור מחדש (reproduce) את התוצאות, תכונה שתאפשר את הבנתן ואת אימותן, לרבות בידי צדדים שלישיים;²⁷⁹ נדרש הליך תיקוף יסודי של המודל, בין השאר כדי למנוע הטיות;²⁸⁰ נדרשת מעורבות מרכזית של בני אנוש בתהליך קבלת ההחלטות.²⁸¹ יוזמות דומות ניתן לראות במדינות נוספות. בסינגפור, מרכז פיננסי עולמי חשוב, הרגולטור הפיננסי פרסם מסמך עקרונות לשימוש בכינה מלאכותית בידי הגופים הפיננסיים. המסמך כולל את ארבעת העקרונות הבאים: הגינות, מוסר, אחריותיות ושקיפות (Fairness, Ethics, Accountability and Transparency – FEAT – Principles).²⁸² בהונג קונג פרסם הרגולטור הפיננסי את מסמך "העקרונות הראשיים על בינה מלאכותית".²⁸³ בהולנד פורסם מסמך "העקרונות הכללים לשימוש בכינה מלאכותית בפיננסים",²⁸⁴ וישנן דוגמאות נוספות. הרושם העולה מסקירת היוזמות השונות הוא שישנה מודעות גבוהה לסיכון ההפליה בעקבות השימוש בכינה מלאכותית, ומכך נובעות ההמלצות המותוות לצמצום הסיכון האמור. ככלל, אפשר לזהות כמה המלצות שעשויות למנוע מקרי הפליה: הקפדה על איכות הנתונים המוזנים למודל; מיסוד תהליכי תיקוף ובקרה למניעת הטיות; הסברותיות; ומעורבות של גורם אנושי לאורך כל תהליך עיבוד המידע.

279 שם, בעמ' 9.

280 שם, בעמ' 10-11.

281 שם, בעמ' 11. ראו בעניין זה גם את ניתוח מקרה הבוחן, שם, בעמ' 10.

282 Monetary Authority of Singapore (MAS), *Principles to Promote Fairness, Ethics, Accountability and Transparency (FEAT) in the Use of Artificial Intelligence and Data Analytics in Singapore's Financial Sector*, MAS (Nov. 12, 2018), available at <https://www.mas.gov.sg/~media/MAS/News%20and%20Publications/Monographs%20and%20Information%20Papers/FEAT%20Principles%20Final.pdf>. מעניין שהרגולטור הסינגפורי נוקט גישה שמרנית יחסית למקביליו במדינות האחרות. במסגרת עקרון ההגינות, המסמך מציין שהפרקטיקה של הבחנה בין קבוצות לקוחות ומתן יחס שונה לכל קבוצה (differential treatment) היא פרקטיקה מקובלת וחלק מהמודל העסקי הנהוג. עם זאת יש להבטיח שפרקטיקה זו לא תגרום לפגיעה לא-מוצדקת באנשים או בקבוצות אוכלוסייה. בהתאם, המסמך מציב את מבחן הצדקה ("justifiability") כתנאי לשימוש בכינה מלאכותית (ראו שם, בעמ' 7). כמו כן המסמך אינו מציב דרישת ההסברותיות, לאור תפיסת המודל האלגוריתמי כחלק מהסודות העסקיים של הגוף הפיננסי (ראו שם, בעמ' 12). ייתכן שהסיבה לגישה זו הוא הרצון לחזק את מעמדה של סינגפור כמרכז פיננסי עולמי ולמשוך אליה פעילות פיננסית, ומכאן המטרה שלא להכביד יתר על המידה על הגופים הפיננסיים.

283 *General Principles for Use of Artificial Intelligence in Finance*, DE NEDERLANDSCHE BANK (Aug. 14, 2019), available at <https://www.dnb.nl/media/voffsrc/general-principles-for-the-use-of-artificial-intelligence-in-the-financial-sector.pdf>

284 Hong-Kong Monetary Authority, *High-level Principles on Artificial Intelligence* (Nov. 1, 2019), available at <https://www.hkma.gov.hk/media/eng/doc/key-information/guidelines-and-circular/2019/20191101e1.pdf>

לאחר שראינו את הגישה הנהוגה במדינות אחרות, נעבור לבדוק את גישת הרגולטורים הפיננסיים בישראל. עוד בשנת 2010 פרסם המפקח על הבנקים "הנחיה בנושא תיקוף מודלים"²⁸⁵. ההנחיה מפרטת את העקרונות הראשיים לתיקוף מודל ממוחשב: בחינה בלתי-תלויה של הביסוס הלוגי והתפיסתי; השוואה מול מודלים אחרים; והשוואת חיזוי המודל לתוצאות בעולם האמיתי. ההנחיה כוללת את ההוראות הבאות באשר לתיקוף שלושת רכיבי המודל: תיקוף של רכיב המידע (קלט) המספק את ההנחות ואת הנתונים המוכנסים למודל, במטרה למנוע שימוש במידע שגוי; תיקוף של רכיב העיבוד של המודל, הכולל את קוד המחשב ואת המודלים התאורטיים שהקוד מיישם; ותיקוף של רכיב הדיווח המתרגם את האומדנים המתמטיים למידע עסקי שימושי.

מטרת ההנחיה היא למזער את הסיכונים הכרוכים בהישענות על מודלים פיננסיים על מנת להגן על הבנקים – על הרווחיות ועל המוניטין שלהם.²⁸⁶ אין בה התייחסות להגנה על הלקוח או לחשש מפני הטיות פסולות או מפני הפליה. עם זאת קיומם של צעדים מסוימים המפורטים בהנחיה עשוי לסייע לצמצום הבעיות האמורות: כך למשל, הסעיף המאפשר לבנק להתבסס על הנחות שונות לצורך בניית המודל, בין כאלו שמקורן במידע פומבי ובין כאלו שמקורן במידע פנימי (כמו בסיס הלקוחות שלו), ובלבד שהוא יהיה מסוגל לספק הסבר ברור לבחירה זו;²⁸⁷ דוגמה אחרת היא הסעיף הדורש מהבנק לספק תיאור ברור – שלא במונחים טכניים – של התאוריה שבבסיס המודל.²⁸⁸ עם זאת ההוראה אינה כוללת דרישת הסברות. בחודש יוני 2020, כשנה לאחר שהחל לפעול מאגר נתוני האשראי בבנק ישראל, הוציא המפקח על הבנקים מכתב לתאגידי הבנקאיים (בנקים וחברות כרטיסי אשראי) בנושא "תיקוף לצורך שימוש במודל דירוג של לשכת אשראי".²⁸⁹ המכתב מפרט את ציפיות הפיקוח בנוגע לתיקוף האמור ומחדד את חשיבותו. עם זאת הוא אינו מחייב את התאגיד הבנקאי לבצע תיקוף שכזה בעצמו, והוא מוכן להסתפק בכך שהתיקוף יתבצע בידי לשכת האשראי באמצעות גורם חיצוני בלתי-תלוי. במקרה שכזה על התאגיד הבנקאי להניח את דעתו באשר לנאותות תהליך התיקוף והתאמתו לסטנדרטים לתיקוף מודלים, בדומה לאלו שקבע התאגיד הבנקאי במדינותיו בנוגע למודלים אחרים של צדדים שלישיים שבהם הוא משתמש. לעניין זה מובן שככל שלרשות התאגיד הבנקאי יעמוד מידע רב יותר על אופן ביצוע התיקוף, היקפו ועומקו, כך הוא יוכל לבחון את נאותות תהליך התיקוף בצורה יעילה ואפקטיבית. עוד מציינ המכתב, כי עקרונות התיקוף של מוצרי ספקים וצדדים שלישיים אחרים המופיעים בהנחיות של הרגולטורים הפיננסיים האמריקניים²⁹⁰ ייחשבו לנהגים

285 בנק ישראל, המפקח על הבנקים: "הנחיה בנושא תיקוף מודלים" (REG10.115.007) (19.10.2010) (עותק בידי המחברות) (להלן: הנחיית המפקח בנושא תיקוף מודלים).

286 שם, בס' 1.2.

287 שם, בס' 4.2.1.

288 שם, בס' 5.2.2.

289 מכתב מדורי בבלי, בשם המפקח על הבנקים, לתאגידי הבנקאיים, בעניין תיקוף לצורך שימוש במודל דירוג של לשכת אשראי (16.6.2020).

290 Board of Governors of the Federal Reserve System and the Office of the Comptroller of the Currency, *Supervision and Regulation Letters: SR 11-7 Guidance on Model Risk Management* (Apr. 4, 2011), available at <https://www.federalreserve.gov/supervisionreg/>

מיטביים מקובלים לעניין זה. ראוי לציין, שהנחיות הרגולטורים האמריקנים מתייחסות במפורש לכך שהמודלים צריכים להיות בני הסבר.²⁹¹ בדומה להנחיית המפקח על הבנקים משנת 2010 שנדונה לעיל, גם מכתב זה אינו מתייחס לצורך להגן על לקוחות מפני הטיות או מפני הפליה פסולה.

חשוב לציין כי אף שהמסמכים האמורים של הפיקוח על הבנקים מוגדרים כ"הנחיה" או כ"מכתב", מדובר בהוראות מחייבות.²⁹²

רשות שוק ההון, ביטוח וחיסכון לא פרסמה הוראות דומות בנוגע לנותני האשראי הכפופים לפיקוחה. בעקבות זאת הם אינם כפופים למגבלות הרבות שלהן כפופים התאגידים הבנקאיים, לרבות החובה לעבוד עם מודלים בני הסבר.

4. חקיקה או רגולציה בנוגע למתן אשראי צרכני

מתן אשראי הוא פעולה מהותית, הן מבחינת המלווה והן מבחינת הלקוח הלווה. מבחינת המלווה, העמדת אשראי מעמידה אותו בסיכון של אי-פירעון האשראי. ראינו כי סיכון זה הוא מהותי במיוחד בקרב גופים המחזיקים בידיהם כספי לקוחות, כדוגמת הבנקים, בשל החשש שאי-פירעון בהיקף גדול עלול לערער את יציבותם.²⁹³ בגופים אלו שיקול היציבות מחייב בחינה יסודית של סיכון האשראי, ולשם כך נדרשת הערכה מדוקדקת של יכולת הפירעון של הלווה. בהתאם, על פי הוראת המפקח על הבנקים בנושא ניהול סיכונים אשראי, הבנק נדרש ל"הבנה יסודית של הלווה", ולשם כך הוא נדרש לאסוף "מספיק מידע" שיאפשר לו לבצע הערכה מקיפה של הסיכון האמיתי של הלווה. בנתונים שעל הבנק לאסוף כלולים נתונים אלה: מטרת האשראי, מקורות הפירעון, ההיסטוריה של הלווה בקשר לפירעון אשראי, יכולת המשפטית לעמוד בהתחייבויותיו ואף היושרה והמוניטין של הלווה.²⁹⁴ אין בהוראה התייחסות לאיסוף נתונים אלטרנטיביים. עם זאת הדוגמאות המפורטות בה עוסקות בנתונים פיננסיים בלבד.

בתחום האשראי ה"חויג-בנקאי" אין הוראה דומה של רשות שוק ההון, ביטוח וחיסכון. אכן, מרבית נותני האשראי ה"חויג-בנקאיים" אינם מחזיקים כספי לקוחות, כך ששיקול היציבות רלוונטי פחות בעניינם. חריג לכך הן פלטפורמות לתיווך באשראי שפעילותן

srletters/sr1107.htm (להלן: SR 11-7). עקרונות אלה אומצו גם בידי תאגיד ביטוח הפיקודנות האמריקני, ה-FDIC. ראו: Federal Deposit Insurance Corporation, *Financial Institution Letters: FIL-22-2017, Adoption of Supervisory Guidance on Model Risk Management* (Jun. 7, 2017), available at <https://www.fdic.gov/news/financial-institution-letters/2017/fil17022.html>.

291 SR 11-7, לעיל ה"ש 290, בעמ' 6, 7, 14, 16.

292 על מידת הציות הגבוהה של הבנקים להוראות המפקח על הבנקים, ראו: רות פלאטורשנער "רגולציה של הבנקים: יציבות מערכתית מול הגנה על צרכנים" רגולציה בישראל – ערכים, אפקטיביות, שיטות 128-129 (אייל טבת ויצחק גלינור עורכים, 2019).

293 ראו לעיל בטקסט שליד ה"ש 167.

294 הוראת ניהול בנקאי תקין 311, לעיל ה"ש 169, עיקרון 4 וס' 26-27.

הולכת ומתרחבת בשנים האחרונות²⁹⁵ וכן אגודות אשראי ופיקדון,²⁹⁶ אולם הוראה דומה טרם הוצאה בעניינן.

מתן אשראי מעמיד בסיכון גם את הלווים. אחת הבעיות שנצפו בשנים האחרונות היא נטייה של צרכנים ליטול אשראי בהיקפים גבוהים שבהם הם לא יוכלו לעמוד, תופעה המהווה "מינוף יתר". כדי להגן על הלקוחות חברו שני הרגולטורים הפיננסיים המפקחים על גופים נותני אשראי – המפקח על הבנקים והממונה על שוק ההון, ביטוח וחסכון – ופרסמו הוראות מקבילות בדבר ניהול אשראי צרכני במטרה לספק הגנה צרכנית ללקוחות הצורכים האשראי.²⁹⁷ ההוראות מוגבלות לאשראי צרכני עד לסכום המרבי הקבוע בחוק אשראי הוגן, התשנ"ג-1993, שנכון למועד כתיבת שורות אלה עומד על 1,197,707 ש"ח, ובלבד שסכום האשראי המצרפי של הלווה בגוף הפיננסי אינו עולה על 5,000,000 ש"ח.²⁹⁸ ההוראה של המפקח על הבנקים בנושא ניהול אשראי צרכני חלה על הבנקים ועל חברות כרטיסי האשראי. ההוראה מחייבת אותם לקבוע מדיניות אשראי צרכני. מסמך המדיניות יכלול בין השאר קריטריונים להעמדת אשראי צרכני ללקוח, ובהם לכל הפחות הערכת האיתנות הפיננסית של הלווה, דירוג הלווה וניסיון מצטבר בהתנהלות הלווה בתאגיד הבנקאי. כמו כן על המסמך לכלול התייחסות לשימוש במאגרי מידע, מקורות מידע פנימיים וחיצוניים, כגון מידע ממאגר נתוני האשראי, ומידע נוסף שיידרש הלווה להציג.²⁹⁹ ההוראה אינה מסתפקת בציון העקרונות לקביעת המדיניות, ומפרטת את התהליכים הנדרשים בעת אישור אשראי. בין השאר היא דורשת לבסס את הליך החיתום על מודלי דירוג.³⁰⁰ הוראה דומה, אם כי מפורטת הרבה פחות, פרסם הממונה על שוק ההון, ביטוח וחסכון, והיא חלה על נותני האשראי הכפופים לפיקוחו.³⁰¹

הוראות אלו בנושא ניהול אשראי צרכני מחייבות למעשה את המלווים לאסוף כמה שיותר מידע על מבקש האשראי. המידע אינו חייב להיות פיננסי דווקא ואין כל מגבלה על מקורות המידע, כך שגם מידע אלטרנטיבי שמקורו ברשתות חברתיות יכול לשמש למטרה זו. אף שמטרת ההוראה היא להגן על הלקוחות מפני מינוף יתר, ומטרת איסוף המידע היא להתאים את האשראי לצורכי הלקוח הספציפי וליכולת הפירעון שלו, ההוראה אינה אוסרת על התאגידים הבנקאיים להשתמש במידע למטרות אחרות כגון בניית מודלי הדירוג שלהם.

295 חוק הפיקוח על שירותים פיננסיים (שירותים פיננסיים מוסדרים), התשע"ו-2016, פרק 3ג.

296 שם, בפרק 1ג.

297 בנק ישראל, הפיקוח על הבנקים "מיישרים קו ברגולציה על אשראי צרכני: הסדרה אחידה של רשות שוק ההון והפיקוח על הבנקים בנושא שיווק אשראי לצרכנים פרטיים במערכת הפיננסית" (הודעה לעיתונות / (25.11.2020) <https://www.boi.org.il/he/NewsAndPublications/PressReleases/Pages/25-11-20.aspx>

298 הוראת ניהול בנקאי תקין 311A, לעיל ה"ש 169, ס' 7; ס' 93 לנספח לחזור נותני שירותים פיננסיים 2020-10-4 של רשות שוק ההון, ביטוח וחסכון "הוראות לניהול אשראי צרכני" (25.11.2020) <https://www.gov.il/BlobFolder/dynamiccollectorresultitem/biconsumercredit/he/2020-10-4.pdf>

299 הוראת ניהול בנקאי תקין 311A, לעיל ה"ש 169, ס' 16.

300 שם, בס' 24.

301 ראו לעיל ה"ש 298.

בארצות הברית הוביל החשש מפני הפליה בחיתום אשראי צרכני לקביעת הסדר מהותי בחקיקה הראשית. ה־Equal Credit Opportunity Act אוסר על נותני אשראי להתחשב בנתונים כמו גזע, דת, מוצא, מין, גיל או מצב משפחתי לצורך חיתום אשראי.³⁰² עם זאת החוק אינו אוסר על התחשבות בנתונים אלטרנטיביים. עניין זה מקשה על לקוחות להוכיח הפליה כשהדירוג נעשה על סמך מודלים אלגוריתמיים המבוססים על נתוני עתק.³⁰³ מנגנון אחר שעשוי לסייע למניעת הפליה הוא מסירת מידע ללקוח על "פעולה פוגעת" (adverse action). החקיקה האמריקנית מחייבת נותן אשראי, אשר בהתבסס על מידע שקיבל מלשכת אשראי סירב להעמיד אשראי ללקוח או נקט פעולה פוגעת אחרת בנוגע לאשראי, למסור ללקוח את הסיבות לכך.³⁰⁴ בדומה לכך, אם התקבלה החלטה הפוגעת בלקוח בהתבסס על דירוג אשראי, על הנושה לגלות ללקוח את ציון הדירוג, את המרכיבים העיקריים שהשפיעו לרעה על הדירוג, את השם ואת פרטי הקשר של לשכת האשראי שערכה את הדירוג ומהן זכויותיו בנוגע למידע זה.³⁰⁵

מידע זה מאפשר ללקוח להתחקות אחר הסיבות להחלטה הפוגעת ולוודא שההחלטה בעניינו התקבלה על סמך נתונים מהימנים ורלוונטיים, ולא נגזרה מהבחנה על בסיס משתנים אסורים לשימוש כגון גזע, דת, גיל, מגדר וכן הלאה. עם זאת מנגנון זה אינו פותר לגמרי את החשש להפליה. ספק אם יש בכוחו לאפשר ללקוח לאתר הפליה היסטורית שמובנית בפריטי המידע המשמשים לבניית המודלים. ספק גדול אף יותר אם יש בכוחו של המנגנון האמור להתמודד עם הסיבה המורכבת יותר להפליה – האופן שנתוני מידע הופכים להיות אינדיקציות לסיכון אשראי, היינו אופן ניתוח המידע.³⁰⁶ זאת ועוד, ככל שמדובר בלקוחות מוחלשים כלכלית, שהם הקבוצה העיקרית העלולה לסבול מהפליה, יש גם להביא בחשבון שרמת האוריינות הפיננסית שלהם בדרך כלל נמוכה. לכן ספק אם מנגנון כאמור, אשר מחייב הבנה של פרטי הדוח, אכן ישים מבחינתם. קושי זה מתעצם נוכח העובדה שנטל ההוכחה בדבר אי-נכונות המידע מוטל על כתפי הלקוחות, במקום שהנטל יהיה על לשכות האשראי להוכיח את נכונות המידע.³⁰⁷ החוק מחייב את הלקוחות לנקוט פעולה יזומה נגד נותן האשראי או לשכת האשראי, בעיה נוספת כשמדובר באוכלוסיות מוחלשות בעלות כוח מיקוח חלש בהשוואה לגופים אלה.

שאלה לא פשוטה היא, אם נותני אשראי יכולים לעמוד בדרישות החוק כאשר דירוג האשראי מבוסס על בינה מלאכותית ועל מודלים אלגוריתמיים מורכבים. כדי להפיג את

302 Equal Credit Opportunity Act, 15 U.S.C. § 1691(a). אך ראו את הסייגים שבסעיפים 1691(b)-(c), שם.

303 Anidjar & Mizrahi-Borohovic, לעיל ה"ש 23, בעמ' 197, Hurley & Adebayo, לעיל ה"ש 107, בעמ' 190-191.

304 Equal Credit Opportunity Act, 15 U.S.C. § 1691(d). הסעיף מאפשר, לחלופין, למסור ללקוח הודעה בדבר זכותו לקבל את הפירוט של סיבות הסיכון. תשובה כללית שלפיה הלקוח לא עמד בדרישות ובקריטריונים של נותן האשראי אינה מספיקה, ראו: 12 C.F.R. § 1002.9(b)(2).

305 Fair Credit Reporting Act, 15 U.S.C. § 1681m.

306 על ההבחנה שבין שני גורמים אלו להפליה, ראו לעיל בפרק ג.

307 Hurley & Adebayo, לעיל ה"ש 107, בעמ' 189.

החששות הללו של הגופים הפיננסיים פרסם הרגולטור הפיננסי הצרכני, ה־Consumer Financial Protection Bureau (CFPB), פרשנות רשמית המגמישה את דרישות החוק במטרה להתאימן למודלים המבוססים על בינה מלאכותית.³⁰⁸ אך למרות הגמישות הפרשנית האמורה, עדיין ישנן אי־בהירויות בנוגע לאופן יישום הוראות החוק על חיתום אלגוריתמי. כך למשל, באשר למתודולוגיות לקביעת הסיבות העיקריות לפעולה פוגעת, הפרשנות הרשמית הכוללת שיטות לדוגמה היא משנת 1982,³⁰⁹ ולא ברור לגמרי כיצד דוגמאות אלו חלות באשר למודלים המבוססים על בינה מלאכותית. אי־בהירות ישנה גם בנוגע לרמת הדיוק של מנגנוני ההסברתיות כאשר הם מיושמים על למידה עמוקה ועל מודלים מורכבים אחרים. קושי אחר מתעורר כאשר לאופן פירוט הסיבות העיקריות שגרמו לפעולה הפוגעת, כך שישקף במדויק ובצורה המובנת ללקוחות את הגורמים המשמשים במודל ובכלל זה את קשרי הגומלין בין מקורות המידע האלטרנטיבי.³¹⁰

בהצעת חוק נתוני אשראי הישראלית הופיעה הוראה דומה להוראה שבדין האמריקני בדבר החובה למסור מידע ללקוח במקרה של החלטה פוגעת. ההוראה חייבה נותן אשראי שקיבל דוח אשראי מלשכת אשראי, ושעל בסיס הדוח סירב להתקשר בעסקת אשראי או שינה לרעה את התנאים של עסקת אשראי שהתקשר בה, להודיע על כך מיד ללקוח ולמסור לו את דוח האשראי, את דיוג האשראי שלו – ככל שהוא נמצא בידיו – וכן פרטים נוספים כפי שורה הממונה.³¹¹ אולם בסופו של דבר שונה נוסח הסעיף לרעת הלקוח. סעיף 31 לחוק נתוני אשראי בסך הכול מחייב נותן אשראי שקיבל דוח אשראי לשם התקשרות בעסקת אשראי עם לקוח (בין אם נכרתה העסקה ובין אם לאו), או שקיבל דוח אשראי לשם הבטחת קיום תנאי עסקת אשראי שהתקשר בה ושינה לרעה את תנאי עסקת האשראי, להודיע על כך מיד ללקוח. בהודעה יימסר ללקוח שזכותו לקבל מנותן האשראי את דוח האשראי שעליו התבסס בהחלטתו, וכן יצוינו פרטי לשכת האשראי שממנה קיבל נותן האשראי את הדוח. רק אם הלקוח אכן יבקש זאת, יהיה על נותן האשראי למסור לו את הדוח.³¹²

מנגנון היידוע הקבוע בדין הישראלי מצומצם משמעותית מהמנגנון הקבוע בדין האמריקני, שכן הוא אינו מחייב את נותן האשראי למסור ללקוח מידע כלשהו בצורה יזומה. לקוח שלא ידרוש עותק מדוח האשראי כלל לא יוכל לברוק את הנתונים שעליהם התבססה ההחלטה בעניינו, כל שכן לוודא כי אלה נתונים מהימנים ורלוונטיים וכי לא היה שימוש במשתנים

Consumer Financial Protection Bureau, § 1002.9 Notifications, CFPB, available at 308
 CFPB, <https://www.consumerfinance.gov/rules-policy/regulations/1002/9/#b-1> (להלן: Notifications).
 Patrice Alexander Ficklin, Tom Pahl & Paul Watkins, ראו: *Notification Innovation Spotlight, Providing Adverse Action Notices When Using AI/ML Models*,
 CFPB (Jul. 7, 2020), available at <https://www.consumerfinance.gov/about-us/blog/innovation-spotlight-providing-adverse-action-notices-when-using-ai-ml-models>

CFPB, Notifications, לעיל ה"ש 308, הערה 5-9(b)(2). 309

Ficklin, Pahl & Watkins, לעיל ה"ש 308; Langenbucher & Corcoran, לעיל ה"ש 161,
 בעמ' 162-163; Eric Knight, *AI and Machine Learning-Based Credit Underwriting and Adverse Action Under the ECOA*, 3 Bus. & Fin. L. Rev. 236 (2020)

311 ס' 29 להצעת חוק נתוני אשראי.

312 הוראה 402 של הממונה על שיתוף בנתוני אשראי בבנק ישראל "מסירת דוח אשראי ללקוח".

אסורים. הביקורת שהובעה לעיל באשר למודל האמריקני תופסת מקל וחומר גם באשר למודל הישראלי. לכן ספק אם יש בכוחו של הסעיף האמור כדי לשמש מנגנון יעיל למניעת הפליה.

ה. הצעות לצמצום הפליה בחיתום אשראי אלגוריתמי

כפי שהראינו בפרקים הקודמים, חיתום אשראי צרכני – בעולם וגם בישראל – מתבסס יותר ויותר על מודלים אלגוריתמיים, העלולים לגרום להפליה אסורה. בעוד שבארצות הברית ובאירופה הסדרים חקיקתיים ורגולטוריים שונים מבקשים לצמצם חששות אלו, נראה כי בישראל אין טיפול מספק בנושא. המהלך הראוי לדעתנו הוא חקיקת חוק ייעודי להסדרת השימוש בבינה מלאכותית בכל תחומי הפעילות במדינה, תוך הכללת אסורים מפורשים בחוק על פרקטיקות העלולות לגרום להפליה. עד להתקנת חקיקה שכזו, אנו קוראות לרגולטורים הפיננסיים להטיל על נתוני האשראי את המגבלות הבאות בנוגע לחיתום אשראי אלגוריתמי, במטרה לצמצם את החשש להפליה בלתי-מכוונת.

1. בקרה פנימית

נקודת המוצא לדיון תהיה כי המודלים האלגוריתמיים לחיתום אשראי, ובכלל זה המודלים המשמשים את לשכות האשראי לצורך הפקת דירוג האשראי, הם מורכבים מאוד,³¹³ דינמיים ואינם חשופים לעיון הציבור.³¹⁴ משכך, כדי למזער את סיכון ההפליה העולה מהשימוש במודלים אלגוריתמיים – הן בשל המידע המוזן למודל והן בשל שיטת עיבוד המידע – יש צורך להגביר את אמצעי הבקרה והפיקוח על הפיתוח ועל השימוש בהם.³¹⁵ בקרה פנימית של המלווים השונים על איכות המודלים המשמשים אותם לצורך חיתום אשראי צרכני היא קריטית. במסגרת זו ראוי להורות על ביצוע הערכה תקופתית כדי לזהות מגמות מפלות שדורשות טיפול (impact assessment).³¹⁶ היתרון המרכזי בהערכות פנימיות שכאלו טמון בכך שלמלווים יש גישה מלאה למודלים האלגוריתמיים – גם מבחינת המידע המשמש להפקתם, גם מבחינת שיטת עיבוד המידע וגם מבחינת ביצועי המודל. אכן, גם אם

Frank Pasquale, *Restoring Transparency to Automated Authority*, 9 J. ON TELECOMM. & HIGH TECH. L. 235 (2011)

314 פרל, לעיל ה"ש 31, בעמ' 175-176.

315 אכן, הצורך לפקח על אלגוריתמים הוכר זה מכבר בספרות האקדמית. ראו למשל: Daniel J. Sterinbock, *Data Matching, Data Mining, and Due Process*, 40 GA. L. REV. 1 (2005); Maayan Perel & Niva Elkin-Koren, *Black Box Tinkering: Beyond Disclosure in Algorithmic Enforcement*, 69 FLA. L. REV. 181 (2017); Robert Brauneis & Ellen P. Goodman, *Algorithmic Transparency for the Smart City*, 20 YALE J.L. & TECH. 103 (2018); Citron & Pasqual, לעיל ה"ש 17.

316 ראו: Yifat Nahmias & Maayan Perel, *The Oversight of Content Moderation by AI: Impact Assessments and their Limitations*, 58 HARV. J. ON LEGIS. 145 (2020); Dillon Reisman et al., *Algorithmic Impact Assessments: A Practical Framework for Public Agency Accountability*, AINOW INSTITUTE (Apr. 2018), available at <https://ainowinstitute.org/aiareport2018.pdf>

המידע המשמש לפיתוח המודל לכאורה אינו כולל תבחינים אסורים כמו לאום, מין ומצב משפחתי, הרי הוא עדיין יכול לייצג תבחינים שכאלו באופן שהאלגוריתם ידע לזהות את הלאום, את הגיל, את המין או את המצב המשפחתי.³¹⁷ לפיכך, בקרה פנימית צריכה לבחון גם את האופן שבו המידע מעובד.

יתרה מזאת, חשוב כי הבקרה הפנימית תהיה תקופתית ולא חד-פעמית. הסיבה לכך היא שמודלים אלגוריתמיים הנשענים על טכנולוגיות של למידת מכונה הם דינמיים, ועשויים להשתנות בהתאם לשינויים במידע המוזן למודל.³¹⁸ אכן, אין די בבחינת המודל מראש, מכיוון שקשה מאוד לצפות מראש אילו מתאמים בין המידע לסיכון אשראי ימצאו האלגוריתמים שבבסיס המודל ואם מדובר במתאמים שיתבררו כמפלים.³¹⁹

זאת ועוד, אין להסתפק בבקרה וולונטרית מצד המלווים, אלא יש לחייבם לערוך בקרה. אכן, למלווים יש אינטרס פנימי-יציבותי לתקף את המודלים האלגוריתמיים שלהם על מנת לוודא שהם מועילים ומהימנים בהערכת סיכון האשראי של לקוחותיהם. אולם אין להסתפק בכך. אנו סבורות כי בחינת השלכותיהם המפלות של מודלים לחיתום אשראי הוא בגדר אינטרס ציבורי שהחובה להגן עליו צריכה להיות מוכתבת מבחון.

גישה שכזו באה לידי ביטוי ביוזמות שונות שננקטו במדינות אחרות, אם כי במסגרת חקיקה כללית בעניין שימושי בינה מלאכותית. כך למשל, הצעת חוק בארצות הברית, The Algorithmic Accountability Act of 2022, מבקשת לחייב חברות המשתמשות במנגנוני קבלת החלטות אלגוריתמיים לבצע הערכה עצמית של השלכות השימוש במערכות בינה מלאכותית (Impact Assessment), בין השאר על מנת לוודא כי המודלים שלהן אינם מפלים, ואף מסמיכה את נציבות הסחר הפדרלית (FTC) לקבוע הנחיות לכיצוע הערכות אלה.³²⁰ באופן דומה, הרגולציה האירופית להגנת המידע (GDPR) מחייבת גופים המעבדים מידע אישי באמצעים אלגוריתמיים לבצע הליך הערכה עצמית (Data Protection Impact Assessment), ככל שעיבוד המידע מציב סיכון גבוה לזכויות הפרט. הבקרה צריכה להיעשות על בסיס קבוע מדי תקופה קצובה, וודאי שבכל פעם שמעדכנים או משנים את מודל החיתום.³²¹ בישראל ישנה הנחיה של המפקח על הבנקים בנושא תיקוף מודלים.³²² ההנחיה עוסקת באופן כללי בתיקוף המודלים שבהם משתמשים התאגידים הבנקאיים לצורכיהם השונים, ואין בה התייחסות מפורשת לחיתום אשראי. ההנחיה מגדירה את התיקוף כ"הליך שמטרתו

317 Gillis, לעיל ה"ש 18, בעמ' 45.

318 Harry Surden, *Machine Learning and Law*, WASH. L. REV. 87, 90 (2014).

319 Joshua A. Kroll et al., *Accountable Algorithms*, 165 U. PA. L. REV. 633, 680 (2017).

320 Algorithmic Accountability Act of 2022, H.R. 6580, S.L.C §117 (2022); Ron Wyden, *Wyden, Booker and Clarke Introduce Algorithmic Accountability Act of 2022 To Require New Transparency And Accountability For Automated Decision Systems* (Feb. 3, 2022), ראו את ס' 3 להצעת החוק הנזכרת. ההצעה חלה גם על שירותים פיננסיים, ראו ס' 2(8)(E), שם.

321 UK INFORMATION COMMISSIONER OFFICE: GUIDE TO THE GENERAL DATA PROTECTION REGULATION (GDPR) 147 (May 15, 2019), available at <https://ico.org.uk/media/for-organisations/guide-to-data-protection/guide-to-the-general-data-protection-regulation-gdpr-1-1.pdf>.

322 ראו את הנחיית המפקח על הבנקים 10LM0779, לעיל ה"ש 285.

הערכת הדיוק של אומדני המודל, ובמסגרתו מוגדרים גם נהלי הפיקוח והבקרה המבטיחים שמירה על דיוק האומדנים. תהליך תיקוף מודל לא רק שמגביר את אמינות המודל, אלא גם מקדם שיפורים והבנה טובה יותר של חזקות וחולשות המודל בקרב ההנהלה ובקרב קבוצות המשתמשים.³²³ מטרת ההנחיה היא להגן על האינטרס של הבנקים, והיא אינה דורשת מהם לערוך בקרה כדי לאתר הטיות פסולות או כדי למנוע הפליה במטרה להגן על הלקוחות. אין הוראה דומה באשר למלווים החוץ-בנקאיים העוסקים בהעמדת אשראי צרכני. אנו סבורות כי ראוי שגם רשות שוק ההון, ביטוח וחסכון תורה על חובת תיקוף המודלים האלגוריתמיים המשמשים את נותני האשראי לצורך חיתום אשראי צרכני. בכל מקרה ראוי, לדעתנו, ששני הרגולטורים יבהירו כי תיקוף זה נועד גם כדי לוודא שהמודלים אינם מבוססים על הטיות פסולות שעלולות להפלות.

לבסוף, אנו סבורות כי ראוי להוסיף על החובה לבצע בקרה פנימית של המודלים האלגוריתמיים לשם מניעת הפליה גם חובת דיווח לרגולטור הרלוונטי על תוצאות הבקרה. אומנם הטלתן של חובות שקיפות מסוג זה ככלי רגולטורי אינה נקייה מביקורת; אין להתעלם מן העלויות הכלכליות הנלוות אליהן³²⁴ כמו גם מן הקושי הפרקטי שביישומן, בפרט כשנושא הביקורת הוא מודלים אלגוריתמיים מורכבים ודינמיים. הואיל והאלגוריתמים עצמם הם קניין פרטי של מפתחיהם, יש להבהיר את היקף הדיווח המתבקש ואת תוכנו.³²⁵ עם זאת ללא חובת דיווח לגוף מפקח חיצוני, אין לדעתנו משמעות אמיתית לבקרה פנימית של המלווים שעשויה להיות צבועה בניגודי עניינים, בפרט נוכח הקושי לפקח על המודלים מבחוץ.³²⁶ לפיכך אנו סבורות כי ראוי לחייב את המלווים לדווח לרגולטור הרלוונטי דיווח תקופתי על ביצוע הבקרה הפנימית, וכן להציג בפניו דוחות המתעדים את אופן ביצוע התיקוף ותוצאותיו.

ישנם אף מי שמציעים לשקול דיווח רחב יותר בדמות פרסום דוחות הבקרה הפנימיים לעיון הציבור, לשם הגברת הפיקוח הציבורי על התאגידים המשתמשים במודלים האלגוריתמיים.³²⁷ לא מצאנו דרישה שכזו בהנחיות הרגולטורים הפיננסיים שהוזכרו בפרק הקודם. הצעה זו, המבוססת על תפיסת הממשל המשותף (collaborative governance) שלפיה הציבור הוא משותף פעיל בפיקוח על הסקטור העסקי תוך שימוש בכלים של חוק רך לשם הגברת הציות והאכיפה,³²⁸ מחייבת דיון במודל הפיקוח הרצוי בסקטור הפיננסי בכלל ובישראל בפרט.

323 שם, בס' 1.3.

324 Mark Fenster, *The Opacity of Transparency*, 91 Iowa L. Rev. 885 (2006).

325 Perel & Elkin-Koren, לעיל ה"ש 315, בעמ' 184.

326 שם, בעמ' 212–221 (השימוש בהנדסה לאחור מתואר כאמצעי יעיל להשגת פיקוח חיצוני על מודלים אלגוריתמיים, אולם בפועל קשה ליישמו נוכח המגבלות המשפטיות והאתיות החלות על השימוש באמצעים כאלו).

327 Margot E. Kaminski, *Binary Governance: Lessons from the GDPR's Approach to Algorithmic Accountability*, 92 S. CAL. L. REV. 1529, 1608-09 (2019) (המחברת מדגישה את החשיבות שבפרסום דוחות בקרה פנימיים לעיון הציבור).

328 ראו למשל: Jody Freeman, *The Private Role in Public Governance*, 75 N.Y.U. L. REV. 543, 663 (2000) (גילוי לציבור יכול לשמש אמת מידה לבחינת אופן התנהלותם הן של הגופים המפוקחים והן של הרגולטורים המפקחים). IAN AYRES & JOHN BRAITHWAITE, RESPONSIVE.

דיון שכזה חורג מתחומי מאמר זה. נציין רק כי לאור חדשנות הנושא והעובדה שעדיין לא נצבר ניסיון מספיק בעריכת בקורות כפי שהצענו, דרישה לפרסם את דוחות הבקרה הפנימיים לציבור היא מוקדמת מדי. כמו כן יש לזכור, שכיום ישנן יכולות טכנולוגיות מתקדמות להפוך נתוני מידע מותממים לנתוני מידע מזהים (re-identification), ולכן, ככל שדוחות שעניינם הפליה יפורסמו לציבור הרחב, יש חשש כי גורמים שונים יוכלו להצליב את המידע המותמם שברוחות עם מידע מזוהה שקיים אצלם על מנת לזהות את הפרט שהחלטה בעניינו.³²⁹ על מנת למנוע מצבים של פגיעה בפרטיותם של לקוחות קונקרטיים שסבלו מהפליה, נדמה כי עדיף להותיר לעת עתה את מלאכת הבקרה לרגולטור הרלוונטי.

עם זאת פרסום לציבור יכול להיעשות בידי הרגולטור. הצעת החוק האמריקנית The Algorithmic Accountability Act, שנזכרה לעיל, המציעה לחייב חברות המקבלות החלטות באמצעות מערכות בינה מלאכותית לבצע הערכה עצמית של השלכות השימוש במערכות אלה, מציעה גם לחייב את החברות להגיש דיווח שנתי לרגולטור (FTC) על הערכות אלה.³³⁰ על בסיס דיווחים אלה מוצע לחייב את הרגולטור לפרסם לציבור דוח שנתי המצביע על המגמות בתחום לרבות סטטיסטיקות ומסקנות, אם כי באופן אנונימי וללא ציון שם התאגידים.³³¹ יותר מכך, על פי ההצעה ה־FTC יקים מאגר פתוח לציבור, שיכלול מידע מוגבל על כל מערכות ההחלטות האוטומטיות הפועלות במדינה ועל הליכי ההחלטות בנושאים חיוניים. המידע יכלול את שם התאגיד, את נושא ההחלטה האוטומטית, ככל האפשר את מקורות המידע המשמשים את המערכת ואת הנוסחאות המשמשות להערכת ביצועי המערכת, וכן מידע אם וכיצד ניתן לתקוף את ההחלטות האלגוריתמיות.³³²

2. התערבות אנושית (human in the loop)

התערבות אנושית בהחלטות חיתום המתבצעות באופן אוטומטי לחלוטין היא אמצעי מהותי לאיתור הטיות פסולות ולמניעת הפליה. בפרט, התערבות אנושית רצויה במקרים שמודל החיתום מבוסס על טכנולוגיות למידת מכונה מורכבות ולא-צפויות, שקשה להבין את ההיגיון שבבסיסן.³³³ זאת ועוד, קיומו של גורם אנושי מתערב ובודק חיונית לצורך הכרה באחריות ובאחריות של המלווים, שלא יוכלו להסתמך על המודלים האלגוריתמיים בעיניים עצומות ולהתנער מאחריות בגין תוצאות מפלות.³³⁴ הגורם האנושי נועד כדי לוודא שהחלטות המתקבלות באמצעים אוטומטיים הן אכן הגיוניות והוגנות.

REGULATION 57-60 (1992) (מודל משולש ששותפים לו הגופים המפוקחים, הרגולטורים המפקחים והציבור).

329 בר־זיו וז'רסקי, לעיל ה"ש 24, בעמ' 127.

330 Algorithmic Accountability Act of 2022, ס' 3(b)(1)(D).

331 שם, בס' 6(a).

332 שם, בס' 6(b).

Ross P. Buckley et al., *Regulating Artificial Intelligence in Finance*, 43 SYDNEY L. REV. 333 (2021), 43, 66.

334 שם, בעמ' 73.

כדי לצמצם את החשש להפליה, מעורבות אנושית דרושה בכל שלבי הפיתוח והיישום של המודל. בפרט, במהלך בניית בסיס המידע המשמש ללמידה מבוקרת נדרשת מעורבות אנושית כדי לוודא שהמידע אינו מוטה מאחת הסיבות שתוארו מוקדם יותר (בפרק ג). בהמשך, במהלך פיתוח מודל החיתום (כלומר בעת הליך הלמידה עצמו), נדרשת מעורבות אנושית שתוודא כי הקריטריון המסווג את המידע אינו משקף תבחיך אסור (כך למשל, כאשר הקריטריון המסווג הוא רמת ההשכלה, ורמת השכלה נמוכה מאפיינת את קבוצת המיעוט). לבסוף, גם במהלך יישום המודל נדרשת מעורבות אנושית מתמשכת לניטור תוצאות המודל כדי לזהות הפליה.

בישראל הרגולטורים הפיננסיים אינם מציבים דרישה כלשהי למעורבות אנושית בהליך החיתום במטרה למנוע הפליה,³³⁵ מצב שלדעתנו דורש שינוי. כך למשל, ברוח מסמך העקרונות שפרסם לאחרונה הרגולטור הפיננסי בגרמניה,³³⁶ ניתן לדרוש ביצוע בדיקה אנושית מדגמית של החלטות אוטומטיות בנוגע להעמדת אשראי כדי לאתר שגיאות. לחלופין, ברוח הרגולציה האירופית להגנת המידע (GDPR),³³⁷ ניתן לאסור החלטות אוטומטיות לחלוטין כאשר לבקשות אשראי בעלות מאפיינים מסוימים כגון אשראי לרכישת השכלה, או כאשר למבקשי אשראי שדורשים מעורבות אנושית בעניינם, הגם שהחלטה אנושית היא איטית יותר מהחלטה אוטומטית. במקרים מיוחדים אלה, לאחר קבלת תוצאת החיתום האלגוריתמי, ההחלטה הסופית בעניין העמדת האשראי תתקבל בידי נציג אנושי, בעל ידע ומומחיות בתחום האשראי.

3. הסברתיות (explainability)

כדי לאפשר פיקוח ובקרה משמעותיים על השימוש במודלים אלגוריתמיים לחיתום אשראי, על המודלים להיות ניתנים להתחקות ולהסבר, תכונה שזכתה למונח "הסברתיות". ככלל, "הסברתיות עוסקת בהסבר הפעולה וההחלטה, דהיינו העלאת מודעות הציבור לדרך הפעולה של המערכת באמצעות מתן הסברים מדוע המערכת הכריעה כפי שהכריעה – גם ברמת הפרט וגם ברמת הכלל".³³⁸

לדרישת ההסברתיות כמה יתרונות חשובים: ראשית, היא מחייבת את המלווים להבין את ההיגיון שבבסיס המודלים המשמשים אותם לחיתום אשראי. כפועל יוצא, ההסברתיות מקילה על מלאכת הבקרה הפנימית מצד המלווים עצמם, ומאפשרת להם לוודא ביתר קלות כי המודל אינו מפלה לרעה. שנית, יכולת ההסבר מקילה על מלאכת הבקרה החיצונית של הרגולטורים. שלישיית, ההסברתיות חשובה כדי לספק ללקוח הסבר על אודות החלטות אוטומטיות המתקבלות בעניינו, ככל שהוא יחפוץ בכך. הסבר זה אמור לספק למי שהחלטה

335 הנחיית המפקח בנושא תיקוף מודלים, לעיל ה"ש 285, מציינת בס' 1.5 שתיקוף המודל דורש לא רק מומחיות פיננסית כי אם גם "שיקול דעת עסקי סובייקטיבי ניכר", היינו נדרשת מעורבות אנושית. אולם מטרתה של מעורבות אנושית זו היא להגן על האינטרס הכלכלי של הבנק, ולא למנוע הטיות ולהגן על הלקוח.

336 BaFin, לעיל ה"ש 276.

337 ראו לעיל ה"ש 269.

338 דוח ועדת משנה של המיזם הלאומי למערכות נבונות, לעיל ה"ש 256, בעמ' 16.

בעניינו מידע ברור, משמעותי וממצה על אודות ההחלטה שהתקבלה,³³⁹ לרבות ציון פרטי המידע שהובאו בחשבון והקריטריון שהכריע.³⁴⁰ כך הלקוח יוכל לוודא כי ההחלטה שנתקבלה בעניינו איננה מוטה.

בישראל הרגולטורים הפיננסיים טרם הציבו דרישת הסברתיות באשר למודלי החיתום האלגוריתמיים. בשל חשיבותה של יכולת ההסבר למניעת הפליה, אנו סבורות כי רצוי שהפיקוח על הבנקים, כמו גם רשות שוק ההון, ביטוח וחיסכון, יגבילו את נותני האשראי הכפופים לפיקוחם לשימוש במודלים הניתנים להסבר.

עם זאת בנוגע לתוכנה ולהיקפה של הדרישה להסברתיות, חשוב ליתן את הדעת להשפעתה האפשרית על החדשנות הטכנולוגית ועל היעילות בתחום. לכאורה, ככל שבוחרים שיטות המוגבלות להסברתיות מלאה, שוללים שימוש בטכנולוגיות מתקדמות יותר שעשויות להיות יעילות ומדויקות יותר אך אינן ניתנות להסבר, מהלך המפחית את רף היעילות והמעכב את החדשנות בתחום. אולם הדברים אינם כך בהכרח: לדרישת ההסברתיות יש מנעד של אפשרויות יישום, ואין מדובר בתופעה בינארית של קיום או של אי-קיום היכולת להסביר. ישנם מודלים לחיתום המבוססים על למידה מבוקרת ואשר מעיקרם ניתנים להסבר, דוגמת מודלים המבוססים על שיטת "היער האקראי",³⁴¹ לעומת מודלים מורכבים יותר של למידה עמוקה (Deep Learning), המבוססים על למידה לא-מבוקרת שאותם ניתן לנסות להסביר רק בדיעבד.³⁴² אם כך, שימוש במודלים של "קופסה שחורה" המבוססים על למידה עמוקה מגביל את מידת ההסברתיות האפשרית בצורה ניכרת, אך אינו שולל אותה בהכרח. מי שתומכים באימוץ מודלים מהסוג הראשון גורסים, כי מבחינת יעילות הם משיגים תוצאות זהות למודלים המבוססים על למידה עמוקה, ואף בעלות נמוכה יותר.³⁴³ לעומת זאת, מי שתומכים באימוץ מודלים מורכבים של למידה עמוקה מצדיקים גישה זו בשל היותם של מודלים אלה מדויקים יותר.³⁴⁴ כמו כן הם גורסים כי ההסברתיות של המודלים הפשוטים יותר מוטלת בספק רב, שכן גם הם מבוססים בסופו של דבר על למידת מכונה שהיא מורכבת להבנתם של בני אנוש.³⁴⁵

339 פרל, לעיל ה"ש 31, בעמ' 193.

340 Kaminski, *The Right to Explanation*, לעיל ה"ש 273, בעמ' 214.

341 Yuan, לעיל ה"ש 145.

342 Jonathan Johnson, *Interpretability vs. Explainability: The Black Box of Machine Learning*, BMCBLOGS (Jul. 16, 2020), <https://www.bmc.com/blogs/machine-learning-interpretability-vs-explainability/>; Leilani Gilpin et al., *Explaining Explanations: An Overview of Interpretability of Machine Learning*, ARXIV (2019), <https://arxiv.org/abs/1806.00069>.

343 D. Sculley et al., *Hidden Technical Debt in Machine Learning Systems*, in 2 NIPS' 15: PROCEEDINGS OF THE 28TH INTERNATIONAL CONFERENCE ON NEURAL INFORMATION PROCESSING SYSTEMS 2503-11 (2015).

344 FinRegLab, לעיל ה"ש 144, בעמ' 35.

345 Zachary C. Lipton, *The Mythos of Model Interpretability*, ARXIV, (2017) <https://arxiv.org/abs/1606.03490>.

אנו סבורות, כי כאשר נקבעת מידת ההסברתיות הנדרשת ממודלים לחיתום אשראי צרכני, חשוב לתת משקל משמעותי לכך שמדובר בשירות בסיסי שכל אדם נזקק לו ואשר עשוי להשפיע בצורה מהותית על התפתחותו הכלכלית, החברתית והאישית. אכן, גם הרגולציה האירופית להגנת המידע (GDPR) מחילה את הזכות להסבר (the right to explanation) על החלטות אוטומטיות לחלוטין או על החלטות שיש להן השלכות משמעותיות על חיי הפרט (כמו החלטות משפטיות).³⁴⁶ בדומה לכך, גם טיוטת הרגולציה האירופית על שימוש בכינה מלאכותית קובעת שעל מקבלי החלטות היוצרות סיכון גבוה לזכויות אדם יחולו דרישות מחמירות יותר, ובכלל זה מערכות לדירוג אשראי.³⁴⁷ גם רשות הבנקאות האירופית, ברוח שיועד לרגולטורים הפיננסיים, הכירה בחשיבותו של עקרון ההסברתיות במסגרת השימוש בנתוני עתק בידי גופים פיננסיים.³⁴⁸ בהתאם לכך אנו סבורות, כי בבוא הרגולטור להגדיר את מידת ההסברתיות הנדרשת במודלי החיתום, ראוי לתת עדיפות לאיסור ההפליה, להציב מגבלות מחמירות יותר על המלווים ולדרוש מהם להשתמש במודלים הניתנים להסבר מעיקרם. בכך תוגבל יכולתם להשתמש במודלים של קופסה שחורה.

4. פתרונות אלטרנטיביים למודרי אשראי

לצד הגברת הפיקוח על השימוש במודלים אלגוריתמיים לחיתום אשראי, ישנה חשיבות גדולה להרחבת הנגישות לאשראי הצרכני לאוכלוסיות אשר בשל הפליה בלתי-מכוונת בהליך החיתום – למשל כתוצאה משעתוק מידע היסטורי מפלה – סובלות מדירוג אשראי נמוך ובשל כך נשללה מהן האפשרות לקבל אשראי.³⁴⁹ אכן, משרד האוצר היה ער לצורך להרחיב את הנגישות לאשראי לאוכלוסיות בעלות דירוג נמוך עוד בשלב הדיונים על חוק נתוני אשראי, כאשר הוא התחייב להקים קרן למודרי אשראי. עם זאת עד למועד כתיבת שורות אלו קרן שכזו טרם הוקמה.³⁵⁰

פתרון (זמני וחלקי) לאוכלוסיות הסובלות מדירוג נמוך מציעים גופים פילנתרופיים המוכנים להעניק להן אשראי למרות הדירוג הנמוך. דוגמה לגוף שכזה היא עמותת "עוגן", המגדירה את עצמה כ"קבוצה פיננסית-חברתית ללא כוונת רווח, המביאה רמה חדשה של הוגנות ושוויון הזדמנויות במגזר הפיננסי, תוך הנגשת אשראי בר-השגה וליווי פיננסי לישראלים הרכיבים המתמודדים עם פערים ומכשולים פיננסיים גדולים".³⁵¹ עם זאת נדגיש, כי אין להסתמך על יוזמות אלו לברן לשם צמצום ההפליה בהעמדת אשראי צרכני. לגופים אלו משאבים מוגבלים, שאינם מספיקים בהכרח למלא את הביקוש לאשראי מצד אוכלוסיות חלשות. למעשה, ארגונים ועמותות פילנתרופיים המעניקים אשראי לאוכלוסיות מוחלשות,

346 ראו הערת פתיח 71 ל-GDPR, לעיל ה"ש 269, וכן ס' 22(1) ל-GDPR.

347 ראו לעיל בפרק ד.2.

348 ראו לעיל בפרק ד.3.

349 כגון האוכלוסייה הערבית הזוכה לדירוג אשראי נמוך, בין השאר בשל סיבות חיצוניות למצבם הפיננסי. ראו לעיל בטקסט שליד ה"ש 205.

350 שם.

351 עוגן, אודות עוגן, ראו בכתובת: <https://www.ogen.org/about-ogen>. העמותה פועלת להקמת

"בנק חברתי", ראו: <https://www.ogen.org/about-ogen/#Future>.

מצליחים בכך בזכות המעורבות האנושית הרבה בתהליך החיתום. החלטות החיתום שלהם אינן אוטומטיות, אלא מבוססות על היכרות אישית עם הלקוח ונסיונותיו האישיות. אולם ברי כי היכולת לבצע חיתום ידני היא מוגבלת – הן מבחינת כמות הלקוחות שאפשר לשרת והן מבחינת משך זמן החיתום – ולכן אין ביוזמות אלו מענה כולל ומספק להפליה. רעיון אחר הוא לעודד את הגופים הפיננסיים עצמם להעמיד אשראי לאוכלוסיות מוחלשות. בארצות הברית רעיון זה בא לידי ביטוי בחוק ההשקעה החוזרת בקהילה (Community Reinvestment Act).³⁵² חוק זה נחקק בשנת 1977 בתגובה לחששות מפני הפליה במתן אשראי, ומטרתו לעודד בנקים וגופים פיננסיים נוספים לתת הלוואות לאוכלוסיות מוחלשות העומדות בקריטריונים בנקאיים סבירים. החוק מחייב את הרגולטורים הפיננסיים לדרג את הבנקים בהתאם לאופן עמידתם ביעדי החוק, ודירוג גבוה מאפשר להם לזכות בהקלות רגולטוריות כגון אישור מיוזמים ותוכניות התרחבות.³⁵³

לבסוף, לצד הרחבת נגישות האשראי לאוכלוסיות מופלות, חשוב גם לשפר את מצבם של לקוחות ללא היסטוריית נתוני אשראי – חסרי הדירוג. לפי נתוני פורום ארלזוורב, נכון לשנת 2020 היו בישראל כ-1,700,000 מודרי אשראי, אשר ל-500,000 מהם לא היה חשבון בנק.³⁵⁴ על מנת לאפשר גם ללקוחות אלו לקבל אשראי, ייתכן שראוי לקדם רגולציה שתחייב את המלווים לשקלל במודלי החיתום שלהם גם נתונים פיננסיים שאינם נתוני אשראי ואפילו נתונים אלטרנטיביים, ככפוף להגנת פרטיות המידע ולבדיקת איכותו, לאור הנתונים האמפיריים שמצביעים על הרחבת הנגישות לאשראי בעקבות עיבוד מידע אלטרנטיבי במסגרת מודלים לחיתום.³⁵⁵

סיכום

חיתום אשראי אלגוריתמי הוא תופעה ההולכת ומתרחבת בישראל, בדומה לנעשה במדינות אחרות. לחיתום האלגוריתמי יתרונות רבים, ובראשם מהירות, יעילות ודיוק. מנגד, חיתום אלגוריתמי עלול לגרום להפליה ולפגיעה באוכלוסיות מוחלשות, אם בשל שימוש בפריטי מידע חוקיים הכוללים הפליה היסטורית מובנית, אם בשל שימוש בפריטי מידע חוקיים כאינדיקציה לקריטריונים מפלים, ואם בשל אופן ניתוח ועיבוד המידע. אכן, חשש זה התברר כמבוסס בשורת מחקרים שנערכו במדינות אחרות ובראשן ארצות הברית. הדרכים האפשריות להתמודדות עם בעיית ההפליה בחיתום אשראי הן מגוונות: החל מחקיקה כללית האוסרת על הפליה במטרה לשמור על ערך השוויון כערך חוקתי, דרך חקיקה

352 12 U.S.C. Chapter 30 (§2901 et seq).

353 ראו: Board of Governors of the Federal Reserve System, *Community Reinvestment Act (CRA)*, (Accessed Jul. 21, 2022), available at https://www.federalreserve.gov/consumerscommunities/cra_about.htm. להצעה ליישם רעיון זה בישראל, ראו: אהרון כהן מוהליבר ואייל סרי "אפליית האשראי בישראל והצעה לפתרון" 10-15 (תוכנית עמיתית קורת – מכון מילקן, 2005).

354 שחר אילן "5 שנים מאז ההתחייבות, הקרן למודרי אשראי טרם הוקמה" כלכליסט (14.12.2020). <https://www.calcalist.co.il/local/articles/0,7340,L-3881470,00.html>

355 ראו לעיל בפרק ג.

כללית המגבילה עיבוד מידע אלגוריתמי בתחומים השונים, וכלה בהוראות קונקרטיות של הרגולטורים הפיננסיים. בישראל המחוקק טרם הסדיר את נושא עיבוד המידע האלגוריתמי, ואין כל חוק האוסר על עיבוד מידע אלגוריתמי באופן היוצר הפליה. חוק איסור הפליה במוצרים, בשירותים ובכניסה למקומות בידור ולמקומות ציבוריים טרם יושם בהקשר של חיתום אשראי אלגוריתמי. גם הרגולטורים הפיננסיים טרם נתנו את דעתם לבעיית ההפליה האפשרית עקב חיתום אשראי אלגוריתמי.

אנו סבורות כי לפני הכול ראוי להסדיר את הנושא בחקיקה ראשית, ולקבוע קביעה ברורה וחד-משמעית כי עיבוד מידע אלגוריתמי באופן היוצר הפליה בין פרטים הוא אסור. עוד אנו סבורות, כי ודאי שכל עוד אין חקיקה שכזו, על הרגולטורים הפיננסיים להציב כמה דרישות בנוגע לחיתום אשראי אלגוריתמי הנעשה בידי המלווים הכפופים לפיקוחם: לחייב בקרות פנימיות, ביצוע הערכות תקופתיות ודיווח על תוצאות הבדיקות; לחייב התערבות אנושית בהליך חיתום אשראי צרכני – בין אם כבקרה רנדומלית על ההחלטה האוטומטית, בין אם בנוגע להלוואות בעלות מאפיינים מיוחדים ובין אם בנוגע ללקוחות שמעוניינים להמתין להחלטה אנושית בעניינם; ולהגביל את השימוש כמודלים לחיתום אשראי למודלים בני הסבר. לסיום הצענו כמה הצעות כדי להקל על מצוקתם של מודרי האשראי. אימוץ המלצות אלה עשוי להוביל לחיתום אשראי אלגוריתמי יעיל והוגן, לטובת המשק והציבור בכללותו.