

### למידה בהשגחה (Supervised Learning): רשתות נוירונים (Neural Networks)

רשת נוירונים מלאכותית או בקיצור ANN (Artificial Neural Network) הינה דרך להתאים (Fitting) מודל לא לינארי לנתונים. משתני היציאה (Outputs) אינם קשורים במישרין למשתני הכניסה (Inputs). קיימות מספר שכבות נסתרות (Hidden Layers) המעורבות בתהליך שכוללות נוירונים. הערכים שבנוירונים בשכבה הנסתרת הראשונה קשורים למשתני הכניסה; הערכים שבנוירונים בשכבה הנסתרת השנייה קשורים לערכים שבנוירונים בשכבה הנסתרת הראשונה; וכך הלאה. משתני היציאה מחושבים מתוך הערכים שבנוירונים בשכבה הנסתרת הסופית (Final Layer).

הפונקציות שמגדירות את הקשרים נקראות פונקציות אקטיבציה (Activation Functions). פונקציית הסיגמואיד (Sigmoid Function), אשר דיברנו עליה בהקשר של רגרסיה לוגיסטית, לעיתים קרובות משמשת כפונקציית אקטיבציה על מנת לקשר בין (א) הערכים שבנוירונים בשכבה הנסתרת בשכבה הנסתרת ה-  $i$  לבין (ב) הערכים שבנוירונים בשכבה הנסתרת ה-  $i-1$ . כאשר אומדים ערכים נומריים או אז פונקציית האקטיבציה שמקשרת בין משתני היציאה לבין הנוירונים בשכבה הנסתרת הסופית היא על פי רוב לינארית. כאשר הנתונים מסווגים, הרי שפונקציית הסיגמואיד מתאימה וראויה יותר עבור השלב האחרון שתואר.

אלגוריתם מורד הגרדיאנט (Gradient Descent) משמש למזעור השגיאה הריבועית הממוצעת (MSE- Mean Squared Error) ברשת נוירונים מסוימת. ניתן לחשוב על חישוב המינימום כעל מציאת התחתית של עמק כלשהו. האלגוריתם עושה צעדים במורד העמק כאשר כל צעד עוקב אחר הקו של המורד התלול ביותר. בחירת הגודל הנכון עבור הצעד, המכונה קצב הלימוד (Learning Rate), הינה היבט חשוב של אלגוריתם מורד הגרדיאנט.



ברגיל, רשתות נוירונים כרוכות בעשרות אלפי פרמטרים. אפילו אם היה אפשר למצוא את ערכי הפרמטרים אשר ממזערים לחלוטין את פונקציית המטרה עבור סט האימון ( Training Set), עדיין הדבר לא היה רצוי היות והוא כמעט בוודאות יסתיים בהתאמת יתר (Over-Fitting), בעיה שכיחה שקיימת באלגוריתמים של למידת מכונה, שבה האלגוריתם לומד טוב מדי את נתוני סט האימון, אך לא נותן תחזיות נכונות לנתוני סט הבדיקה). בפרקטיקה, כלל עצירה (Stopping Rule) מיושם כך שאימון באמצעות אלגוריתם מורד הגרדיאנט נעצר כאשר התוצאות המתקבלות עבור סט האימות (Validation Set) חורגות מהתוצאות המתקבלות עבור סט האימון.

רשת נוירונים קונבולוציונית (Convolutional Neural Network) או בקיצור CNN הינה רשת נוירונים שבה הנוירונים בשכבה אחת קשורים לתת-קבוצה של נוירונים בשכבה הקודמת במקום לכול הנוירונים בשכבה הקודמת. CNN שימושי במיוחד לעיבוד תמונה זיהוי תמונות (Image Recognition) וזיהוי אובייקטים בתמונה (Object Detection) כאשר משתני הכניסה מוגדרים על ידי צבעים של עשרות אלפי (או אפילו מיליוני) פיקסלים. רשת נוירונים חוזרת (Recurrent Neural Network) הינה ורסיה של ANN אשר מתאימה במיוחד למצבים שבהם המודל המיועד לניבוי משתנה היציאה צפוי להתפתח על פני זמן.

### פרטים אודות כותב המאמר: האקטואר רועי פולניצר, FRM

רועי בעל תואר שני במימון (התמחות בניהול סיכונים ואקטואריה) ותואר ראשון בכלכלה (התמחות במימון), שניהם מאוניברסיטת בן-גוריון בנגב, בעל דיפלומה בניהול סיכונים פיננסיים (FRM®) מאוניברסיטת אריאל בשומרון ולמד בתוכנית ללימודי תעודה באקטואריה באוניברסיטת חיפה. כמו כן, רועי אקטואר מלא



(Fellow) בלשכת מעריכי השווי והאקטוארים הפיננסיים בישראל (F.I.L.A.V.F.A.), מוסמך כמעריך שווי מימון תאגידי (CFV) מטעם לשכת מעריכי השווי והאקטוארים הפיננסיים בישראל (IAVFA), מוסמך כמנהל סיכונים פיננסיים (FRM) מטעם האיגוד העולמי למומחי סיכונים (GARP) ומוסמך כמומחה לניהול סיכונים (CRM) מטעם האיגוד הישראלי למנהלי סיכונים (IARM).

לרועי ניסיון של מעל ל-15 שנה בביצוע ניתוחים כמותיים במכשירים פיננסיים, בהערכת שווי תאגידים ונכסים בלתי מוחשיים, באמידה וכימות סיכונים כמו תמותה, אריכות ימים, תחלואה, ביטולים והחלמה מנכות, ובמידול ומדידת סיכוני שוק, אשראי, תפעוליים, מודל, נזילות והשקעות לצורכי יישום הוראות רגולטוריות ותקינה חשבונאית, פיתוח, יישום ותיקוף מודלים בתחומים של הערכות שווי, ניהול סיכונים, אקטואריה והנדסה פיננסית, קביעת תעריפי ביטוח חיים, הערכת פרמיות סיכון והערכת עתודות ביטוח, קביעת עלות תנאי פנסיות (צוברות ותקציביות) והכנת מאזנים אקטואריים לקרנות פנסיה, ניתוח וחיזוי מצבים פיננסיים מורכבים וכן העברת סמינרי הדרכה והשתלמויות בתחומי התמחותו: מימון, אקטואריה, הערכות שווי, בנקאות, ניהול סיכונים, אופציות והנדסה פיננסית.



ניסיונו של רועי בתחום ה-Data Analysis, כולל: עבודה עם מאגרי מידע גדולים Big Data תוך שימוש ב- Statistical Learning (כגון: סטטיסטיקה תיאורית, הסתברות, הסקה סטטיסטית, סטטיסטיקה א-פרמטרית, חלוקת נתונים, נרמול נתונים, Fitting ו- Bayes Theorem) ובאלגוריתמים מסוג Unsupervised Learning (כגון: Hierarchical k-means Clustering, Clustering, Density-based Clustering, Distribution-based Clustering ו- Principle Components Analysis) למציאת דפוסים וזיהוי מגמות ואנומליות בעולמות ניהול הסיכונים, ההשקעות, האקטואריה, הביטוח והפנסיה, פיתוח תשתית לצורך ניתוח נתונים, שילוב והטמעת כלים לצורך גישה ושליפה עצמאית של נתונים ממאגרי מידע, פיתוח דוחות, ממשקים ומסכים באמצעות כלי ויזואליזציה.

ניסיונו של רועי בתחום ה-Data Science, כולל: עבודה עם מסדי נתונים גדולים Big Data תוך שימוש באלגוריתמים מסוג Supervised Learning (כגון: Linear Regression, Ridge Regression, Lasso Regression, Elastic Net Regression, Logistic Regression, Maximum Likelihood Estimation, k-Nearest Neighbors, Decision Tree, Random Forest, Ensemble, Bagging, Boosting, Naïve Bayes Classifier, Linear Separation, Support Vector Machine, Non-Linear Separation, SVM Regression, Artificial Neural Network, Convolutional Neural Network ו- Recurrent Neural Network) לניבוי וסיווג בעולמות ניהול הסיכונים, ההשקעות, האקטואריה, הביטוח והפנסיה ובמדלים מסוג Reinforcement Learning (כגון: Q-learning, Monte Carlo Simulation, Temporal Difference Learning ו- n-Step Bootstrapping) לקבלת החלטות מרובות שלבים בעולמות ניהול הסיכונים, ההשקעות, האקטואריה, הביטוח והפנסיה, זיהוי אתגרים עסקיים שבהם DATA יכול להוות גורם מכריע בשיפור קבלת החלטות, איתור ואיסוף מקורות מידע, הגדרה ואיפיון של שימושי המידע, בניית מסד המידע, אפיון והגדרת הצגת המידע



ותוצריו, פיתוח כלים, מודלים, תהליכים ומערכות בתחום האנליזה, תוך שימוש בכלי אנליזה מתקדמים (EXCEL, VBA ו-R).