

אמידת שיאי ביקוש לחשמל במדינת ישראל בעזרת מודלים של למידת מכונה

ד"ר משה קלנר¹, הדר מרגלית¹, רועי אלמקייס¹

הנגישות למידע ממגוון מקורות, לצד ההתפתחויות הטכנולוגיות המאפשרות אגירת מידע במסדי נתונים ענקיים ופיתוח מודלים של למידת מכונה (Machine Learning) לניתוחם, תורמות לשיפור מהירות התגובה והדיוק בתחומים רבים המשפיעים על חיי היומיום. אחד התחומים המרכזיים הוא מגזר החשמל, בו כלים אלו משמשים לניהול ביקושים ולשיפור יכולות החיזוי של צריכת החשמל. אמידת שיאי הביקוש לחשמל מהווה גורם קריטי לניהול של מערכות החשמל, במיוחד לנוכח המעבר המתגבר לשימוש במקורות אנרגיה מתחדשים (בעיקר אנרגיה סולרית מהשמש) והתקדמות טכנולוגית כמו מונים חכמים ותשתיות מדידה מתקדמות, המאפשרות ניהול ביקושים. תחזיות מדויקות של שיאי הביקוש ומועדיהם מאפשרות למנהלי מערכת בעולם ובמדינת ישראל בפרט, להיערך בצורה מיטבית, להפחית עומסים על הרשת וליעל את השימוש במשאבים. האתגרים החדשים, הנובעים מהתחממות גלובלית והשפעתה על הביקושים לחשמל, שינויים במאפייני הצריכה, וחדירת טכנולוגיות עתירות אנרגיה כמו רכבים חשמליים, מציבים קושי רב בפני שיטות החיזוי המסורתיות. שיטות אלו אשר היו בשימוש נרחב בעשורים האחרונים מבוססות בעיקר על ניתוח סדרות זמן, ואינן מתאימות במידה מספקת לדפוסי הצריכה המודרניים, המאופיינים באי-ליניאריות ודינמיות. מאמר זה נותן מענה לאתגרים אלו. המאמר עוסק באמידת שיאי הביקוש לחשמל במדינת ישראל לטווח הקצר (עד חמישה ימים) בעזרת שיטות של למידת מכונה המאפשרות יכולות חיזוי משופרות המותאמות טוב יותר למורכבות שבחיזוי ביקושי החשמל בישראל. במאמר נציג את השיטות השונות לאמידת הביקוש, התאמתן לעונות השנה, אופן בחירת המודל הטוב ביותר, השיטות לאמידת דיוק המודל והתאמתן למערכת החשמל הישראלית.

מילות מפתח: שיאי ביקוש לחשמל, למידת מכונה, מודלים סטטיסטיים, חיזוי טווח קצר, ניהול ביקושים.

1. מבוא

התקדמות בנגישות למידע ובטכנולוגיות השימוש בו הובילו לכך שבשנים האחרונות חלה התקדמות משמעותית בשימוש במודלים של למידת מכונה (ML) במגוון רחב של יישומים עסקיים ובדגש על כלים המאפשרים חיזוי מדויק. ארומגום ואחרים (2023), השתמשו במודלים בתחום הרפואה, בכדי לחזות את הסבירות למחלות לב. החוקרים הוכיחו שמודל Decision Tree (DT) מכון פרמטרים מאפשר חיזוי מדויק יותר מהמתקבל על ידי מודל Support Vector Machines (SVM) ומודל Naïve Bayes. מוסאבי ואחרים (2018), בחנו את השימוש במודלים של למידת מכונה לצורך חיזוי שיטפונות בטווח הקצר ככלי למניעת נזקים והתמודדות מוקדמת עם מצבי חירום. המחברים דנו ביעילותם של מודלים כגון Artificial Neural Networks (ANN), SVM ו-DT בשיפור דיוק החיזוי לשיטפון. החוקרים הוכיחו ששימוש בכלים של למידת מכונה אפשרו חיזוי מדויק של מועד ועוצמת השיטפונות בדיוק גבוה. אדן ואחרים (2021), השתמשו בשלושה מודלים בכדי לחזות את טמפרטורת האוויר. מבין שלושת המודלים שנוסו, מודל Least Square Support Vector Machine (LSSVM) היה המדויק ביותר.

בתחום החשמל, המתאפיין בהתפתחות מהירה של טכנולוגיות ייצור, מרכיבי ביקוש משתנים, שונות גבוהה בסך הביקוש ובביקוש בשעות השיא, נבחנו מודלים של למידת מכונה לצורך דיוק החיזוי. נושא זה מקבל חשיבות מכיוון שניהול נכון של הביקוש לחשמל ושיטות אמינות לחיזוי הביקוש חיוניים לאופטימיזציה של תפעול מערכת החשמל. מספר רב של חוקרים הציעו פתרונות לבעיה זו בעזרת שימוש במודלים של למידת מכונה, שהשכיחים בניהם הינם:

Linear Regression (LR), Support Vector Regression (SVR), Random Forest (RF), K-Nearest
.Multi-Layer Perceptron (MLP), DT, Neighbors (KNN)

¹ נגה, חברת ניהול המערכת, היחידה לחיזוי ומחקר סטטיסטי

גונזאלס ואחרים (2019), סקרו את השימוש במגוון מודלים של למידת מכונה לצורך חיזוי צריכת חשמל. החוקרים ניסו לזהות אילו מודלים מספקים את התחזיות המדויקות ביותר בחיזוי צריכת החשמל הביתית, ולבחון את המשתנים המשפיעים ביותר על התחזיות. כל מודל נבדק עם משתנים מסבירים כמו יום בשבוע, צריכת חשמל של היום הקודם, והאם מדובר ביום עבודה או בסוף שבוע. התוצאות הצביעו על כך ש-SVR ו-LR היו המובילים בזכות הכללת משתנה צריכת החשמל ביום הקודם במודל. החוקרים ציינו כי איכות הנתונים והמשתנים הנבחרים לתהליך הלמידה משפיעים באופן מכריע על דיוק התחזית, וכי יש חשיבות רבה בבחירת פרמטרים מתאימים בתהליך ההכשרה. גישה היברידית לחיזוי צריכת חשמל של מכשירי חשמל ביתיים וביקושי שיא הוצגה על ידי הק ואחרים (2020), החוקרים השתמשו בגישה המשלבת את המודלים: ANN ו-SVM יחד עם K-Medoids Clustering לצורך שיפור דיוק ומהירות החיזוי. המודל הצליח להשיג דיוק גבוה של 99.2% בתחזיות הצריכה. במאמר הודגשה החשיבות של חיזוי ביקושי שיא כדי לאפשר לצרכנים לשפר את ניהול האנרגיה שלהם ולהפחית צריכה בשעות העומס. אגילר ואנטוניו (2021), בחנו יישום טכניקות למידת מכונה לשיפור תחזיות הביקוש לטווח קצר במערכת החשמל של פנמה. החוקרים הדגישו את החשיבות של תחזיות מדויקות לאור התלות הגוברת באנרגיות מתחדשות, המכניסות שונות רבה וחוסר ודאות לייצור החשמל. המחקר עושה שימוש בסט נתונים מקיף הכולל נתוני ביקוש היסטוריים ומשתנים מטאורולוגיים, ובו נבדקו מספר מודלים, ומודל ה-Extreme Gradient Boosting (XGBoost) הוביל לתוצאות המדויקות ביותר. יתרון נוסף שצוין למודל זה הוא יכולתו להדגיש את חשיבותם של משתנים המשפיעים על הביקוש. לי וצ'או (2022), הראו שמודלים של למידת מכונה, מתעלים ברוב המקרים על השיטות המסורתיות ומשפרים את דיוק התחזיות באופן ניכר, במיוחד כאשר משתנים אקסוגניים כמו טמפרטורה, לחות וגורמים מטאורולוגיים אחרים נלקחים בחשבון. בנוסף, ציינו החוקרים כי ביקושי השיא לחשמל נוטים לעקוב אחר דפוסים עונתיים, עם עומסים גבוהים בחודשי הקיץ והחורף, ועומסים נמוכים יותר באביב ובסתיו. הבנה של שינויים עונתיים אלו הכרחית להשגת תחזיות מדויקות. תפקיד התחזיות לטווח קצר בתפעול יעיל של מערכות חשמל הוצג על ידי גואו ואחרים (2021), המאמר מדגיש את האתגרים בתחזיות מדויקות של צריכת החשמל, עקב אי הוודאות בתנאי מזג האוויר והתנהגות הצרכנים, המכניסים שונות רבה למודל. המחקר סוקר מספר טכניקות של למידת מכונה לחיזוי הביקוש לחשמל. החוקרים מציעים מודל משולב שממזג בין השיטות ומספק דיוק גבוה יותר בתחזיות ובכך החוקרים מתגברים על המגבלות של המודלים הבודדים. שינוי נוסף שעובר משק החשמל הוא התקנת המונים החכמים המאפשרים חילופי מידע בזמן אמת בין ספקי החשמל למשתמשי הקצה. שימוש במידע זה מוביל ליעילות באספקת החשמל ומעודד יישומי אנרגיה חכמים וניהול ביקושים. טכניקות שונות של למידת מכונה המיועדות לחזות את צריכת מכשירי החשמל וביקוש השיא באמצעות שימוש בנתונים שנאספו מהמונים החכמים הוצגו על ידי אברה וחדקר (2020). המחקרים מדגימים את יעילות המודלים בהשגת שיעורי דיוק גבוהים המגיעים עד 99.6% בחיזוי השימוש בחשמל. התוצאות מצביעות על כך שגישות אלו תורמות לשיפור משמעותי בהבנת דפוסי הצריכה, מאפשרות יישום אסטרטגיות ניהול אנרגיה טובות יותר ותומכות בתכנון וחלוקת משאבים מצד חברות ניהול המערכת.

במדינת ישראל מספר משקי הבית בעלי מונים חכמים מתקרב למיליון ומהווה כשליש מכלל משקי הבית ובכונות המדינה שבשנים הקרובות כלל המונים הביתיים יהיו חכמים. שינוי זה מעצים את החשיבות של חיזוי מדויק של שיאי הביקוש לחשמל אשר יאפשר ניהול ביקושים אופטימלי, יחסוך כסף למשק ולצרכן ועשוי לצמצם את הפליטות הנגרמות מייצור החשמל. גם בהיבט של שינויי האקלים, מדינת ישראל שונה ממדינות רבות ובשל מיקומה הגאוגרפי היא מושפעת ותושפע בעתיד מההתחממות הגלובלית. יוסף ואחרים (2019), טענו שבעתיד הקרוב האקלים בישראל צפוי להיות חם ויבש יותר, תחול עלייה במספר הימים והלילות החמים וירידה בימים הקרים וקיים צפי לעליית השכיחות והעוצמה של תופעות מזג אויר קיצוניות. שינויים אלה משפיעים רבות על הביקושים ומאתגרים את יכולת הדיוק של חיזוי החשמל לטווח הקצר הדרוש למנהל המערכת בכדי לקבוע את הקצאת היחידות ליום הבא.

העבודה המתוארת במאמר זה נועדה לסייע בהתמודדות עם אתגר זה, בה נציג את מודל החיזוי לשיא הביקוש לחשמל לטווח הקצר (עד חמישה ימים) בעזרת מודלים של למידת מכונה. העבודה נעשית ביחידת החיזוי והמחקר הסטטיסטי בחברת נגה, מנהלת מערכת החשמל, ומהווה כלי עזר לחזאי הביקוש לחשמל בחברה. בפרק מספר 2


נציג את שיטות האמידה, האתגרים והפתרונות אותם בחרנו ליישם. תוצאות המחקר יוצגו בפרק מספר 3 וסיכום יוצג בפרק מספר 4.

2. מתודולוגיה



אמידת שיאי הביקוש לחשמל נעשתה על ידי שימוש בחמישה מודלים של למידת מכונה. שילוב (Ensemble) המודלים מותאם לחודשי השנה, כאשר חודשי הקיץ (יולי - ספטמבר), החורף (דצמבר, ינואר ופברואר) ועונת המעבר החמה (מאי ויוני) קובצו יחד. לכל מודל, בכל עונה נבחרו המאפיינים (Features) ונקבעו הפרמטרים המתאימים. נוסו מספר רב של מודלים, להלן המודלים שנבחרו.

2.1 המודלים הנבחרים:


Random Forest: אלגוריתם למידת מכונה המשמש למשימות סיווג ורגרסיה, המבוסס על בניית אוסף של עצי החלטה. האלגוריתם פועל בשיטת ריבוי מודלים של עצי החלטה (Ensemble) בכדי לשפר את הדיוק הכללי ולמנוע התאמת יתר (Overfitting). כל עץ החלטה במודל פועל באופן עצמאי, והתחזית הסופית מתבצעת על ידי קיבוץ תוצאות החיזוי של כל העצים.




Multilayer Perceptron (MLP): רשת עצבית מלאכותית המורכבת משכבות מרובות של צמתים (נוירונים) ומכילה שכבת קלט, אחת או יותר, שכבות נסתרות, ושכבת פלט. כל הנוירונים בכל השכבות מחוברים אחד לשני וכך נוצרת רשת המאפשרת למודל ללמוד דפוסים מורכבים בנתונים. המודל מסוגל ללמוד פונקציות לא-ליניאריות מורכבות על ידי שימוש בפונקציות אקטיבציה לא-ליניאריות.



Support Vector Regression (SVR): אלגוריתם לחיזוי המתמקד בהתאמת פונקציית חיזוי בתוך מרווח שגיאה סביב הערכים החזויים. המודל פועל על ידי מציאת ה- hyperplane האופטימלי המתאים ביותר לנתונים בתוך השוליים הללו, תוך מתן אפשרות לשגיאות מסוימות בתוכן. SVR יעיל, במיוחד במרחבים בעלי מימדים גבוהים, והוא מתאים למקרים שבהם ייתכן שהנתונים אינם ליניאריים ודורשים גמישות בהגדרת מרווח השגיאה המקובל.



Extreme Gradient Boosting (XGBoost): אלגוריתם הבונה סדרה של עצי החלטה ברצף, כאשר כל עץ חדש מתקן את השגיאות שנעשו על ידי הקודמים. מודל זה, ממזער שגיאות חיזוי על ידי התאמת מודלים הנבנים בהתבסס על תצפיות שנחזו בעבר בצורה שגויה. באמצעות טכניקות אופטימיזציה והסדרה, שואף המודל ליצור מכלול עוצמתי של עצים ולשפר את המהירות והדיוק בתחזיות עבור משימות למידת מכונה שונות.



Long Short-Term Memory (LSTM): רשת עצבית חוזרת (Recurrent Neural Network - RNN) אשר נועדה להתמודד עם סט נתונים הכולל בתוכו סדרות זמן. המודל יעיל בלכידת תלות ארוכת טווח בין התצפיות. ל-LSTM יש ארכיטקטורה מורכבת יותר בהשוואה ל-RNNs מסורתיים, עם תאי זיכרון מיוחדים שיכולים לשמור מידע על פני רצפים ארוכים, מה שהופך אותם למתאימים למשימות כמו עיבוד שפה טבעית, זיהוי דיבור וחיזוי סדרות זמן.

2.2 אמידת שיאי ביקוש לחשמל במדינת ישראל:

נתונים:

המאפיינים המשפיעים באופן המובהק ביותר על חיזוי שיא הביקוש לחשמל ביום הבא הינם הביקושים ההיסטוריים (יום ויומיים קודם) ומשתני מזג אוויר. עבור משתנים אלו, מתקבלים מאתר השירות המטאורולוגי 164 מאפייני מזג אוויר שונים בכל שלוש שעות. הנתונים מצטברים ברמה יומית, החל מינואר 2000 וכוללים טמפרטורות, ערכי לחות, כמויות גשמים, מהירות וכיוון רוח ועוד. בנוסף לנתונים אלו, הוספנו למודל מאפייני עומסי חום, המחושבים על פי משוואה מספר 1, הכוללים עומסי חום שעתיים, עומס חום יומי מקסימלי, ממוצע עומס חום יומי, מספר ימים חמים/קרים, יחס בין ימי חול לחגים וסופי שבוע ומשתנים תלויי זמן (לדוגמה שיא הביקוש אתמול ושלשום), טמפרטורה מקסימלית/מינימלית אתמול, עומס חום מקסימלי של אתמול ועוד.

(1)

$$Heat Stress_{ij} = \left(\frac{6.1121 \times Humidity_{ij}}{100} \times e^{\frac{18.678 - Temperature_{ij}}{234.5}} \times \frac{Temperature_{ij}}{257.14 + Temperature_{ij}} \right) \times 0.348 + Temperature_{ij} - 4.25$$


עבור יום בשבוע i ושעה ביום j .

נרמול שיאי הביקוש:

בכל שנה נוספים חידושים טכנולוגיים תלויי חשמל, הטמפרטורות מתחממות וגדלה כמות האוכלוסייה בישראל וסך צריכת החשמל ושיאי הביקוש עולים בהתאמה. כתוצאה מכך שיאי ביקוש משנים קודמות שנמצאים בסט הנתונים אינם משקפים את שיאי הביקוש הקיימים כעת. כדי לפתור בעיה זו, מתבצע נרמול לשיאי הביקוש והם מותאמים לזמן הנוכחי. לדוגמה, בגרף מספר 1 מוצגים ביקושי החשמל החודשיים משנת 2010 עד 2024.

גרף מספר 1: סך ביקוש חודשי לחשמל במדינת ישראל בשנים 2010 – 2024:

ניתן לראות מהגרף כי קיימת שונות גדולה בערכי סך הביקוש החודשי (KWh) בין השנים אך מגמת הביקושים לחשמל עולה באופן עקבי. בנוסף, העונות בהם צריכת החשמל היא הגבוהה ביותר הינן החורף והקיץ.




מבנה מסד נתוני החיזוי:

סט הנתונים עליו בוצע המחקר פוצל לשתי תקופות, תקופת אימון Train (שנים 2000-2021) ותקופת אימות Validation (שנים 2022-2023), עליה נבחנו כל אחד מהמודלים ונקבעו הפרמטרים המתאימים לכל מודל בכל עונה ולכל סוג יום. בישראל, בקיץ ובחורף הטמפרטורות קיצוניות יותר, וכך גם הביקוש לחשמל. בנוסף, בקיץ טמפ' מקסימום משפיעה יותר מטמפ' מינימום בכל יום ומעלה את הביקוש לחשמל ובחורף להפך. גם התנהגות הצריכה בין ימי חול וימי חג או סופי שבוע משתנה. במטרה להתאים את המודל להשפעות העונתיות והשפעות לוח השנה כל אחת מהתקופות בסט הנתונים חולקה לעונות ולסוגי יום (חגים, סופי שבוע וימי חול). החל משנת 2024, בכל יום מתבצעת השוואה בין האומדן ביום החיזוי הקודם לערך שיא הביקוש האמיתי (תקופת בחינה Test). המודל מכון ומתוקן בהתאם לסטיות המתקבלות.

בחירת מאפיינים עבור תקופות המחקר השונות:

במטרה לצמצם את כמות המאפיינים ולבחור את המתאימים ביותר לתקופה הנבחרת, נבחרו אלו בעלי השונות המוסברת הגבוהה ביותר, לכל תקופת חיזוי. בגרף מספר 2 מוצגת מידת חשיבות המאפיינים במודל RF ובגרף מספר 3 מתואר כיצד כל מאפיין במודל משפיע על התוצאה החזויה של הביקוש לחשמל.

גרף מספר 2 (ימני) בחירת המאפיינים עבור מודל קיץ בימי חול **וגרף מספר 3** (שמאלי) - השפעת המאפיינים במודל.




מהגרפים ניתן לראות שהמאפיין המשפיע ביותר עבור תקופת הקיץ הוא שיא הביקוש שהיה ביום הקודם (T1), ולו קשר חיובי לאומדן שיא הביקוש ביום הנוכחי.

ייצוג סינטטי של תצפיות (שיאי ביקוש לחשמל) חריגות:

אחת המגבלות בעבודה עם שיטות למידת מכונה היא התלות בנתונים היסטוריים בעזרתם המודל מאומן. במציאות של היום, במדינת ישראל, עם ההתחממות הגלובלית, ימים נעשים חמים יותר בקיץ, דבר הגורם לימי קיצון בהם יש שבירת שיאי ביקוש אשר לא מיוצגים בנתונים ההיסטוריים.

כדי להתגבר על בעיה זו, סונטזו תצפיות חדשות תוך שמירה על התפלגות הנתונים ובכך ניתן ייצוג לזנב ההתפלגות, ותצפיות קיצון שלא מיוצגות בנתונים ההיסטוריים קיבלו ביטוי במודל. כפי שניתן לראות בגרף מספר 4.

גרף מספר 4: התפלגות הנתונים הערכים המסונטזים (גרף שמאלי) ו-התפלגות משותפת של ערכי הסנטז לפני ואחרי הפעולה (גרף ימני).




בגרף הימני הערכים המסונטזים מיוצגים באמצעות הצבע הירוק בהיר והאמתיים בצבע ירוק כהה. ניתן לראות כי כמות התצפיות המקורית בזנב ההתפלגות הימני קטנה משמעותית מכמות התצפיות המסונטזות.

2.3 קביעת האומדן הטוב ביותר:

בחירת המודל המתאים ביותר לנתונים או שיטת המשקול של שילוב המודלים הינה שאלה בעלת חשיבות מכרעת בדיוק מודל החיזוי. זאת משום שבעוד שבכל ריצה מתקבלים אומדני שיא הביקוש לחשמל עבור חמשת מודלי למידת המכונה הנבחרים, בימים מסוימים ערכי האומדנים קרובים זה לזה ובאחרים רחוקים זה מזה. בנוסף, בימים שונים התוצאה המדויקת ביותר מתקבלת על ידי מודל אחר, כפי שניתן לראות בגרפים 5 ו-6.


גרף מספר 5: תוצאות דיוק המודלים עבור האומדן הטוב ביותר ועבור אנסמבל המודלים הממושקל

מהגרף ניתן לראות שערכי השגיאה הממוצעים של המודל הטוב ביותר המחושבים בדיעבד (כחול בהיר) בכל שבוע מדויקים יותר מחישוב האומדן הממושקל של מספר אומדנים המתקבלים ממודלים שונים.



גרף מספר 6: תוצאות אומדני שיא הביקוש וערך הסטייה (APE) של חמשת המודלים בתאריך 04/08/2024

מהגרף ניתן לראות ששיא הביקוש המשקי לחשמל המוצג על ידי הקו הירוק המקווקו שווה ל-14.1 גיגה-וואט. האמד המדויק ביותר לשיא הביקוש התקבל על ידי מודל MLP (סטייה של 0.5%). ממוצע כלל המודלים המוצג בעזרת הקו המקווקו הכתום הינו 14.7 גיגה-וואט (סטייה של כ-4.5%). האמד של המודל המשוקלל, המוצג על ידי הקו הכחול המקווקו מנבא שיא של 14.4 גיגה-וואט (סטייה של 2.2%) ומאפשר התאמה טובה יותר בין המודל הטוב ביותר (אותו לא ניתן לחזות מראש) לבין ממוצע פשוט של כלל המודלים המכיל את המודל הפחות מדויק.



2.4 בחירת המודלים המשפיעים על האומדן:

שיטות למידה שונות משפיעות על האומדן המתקבל. גורמים חיצוניים, כגון שינויים חריגים בטמפרטורה, עשויים לשנות את הביקוש הצפוי ולגרום לסטייה בשיאי הביקוש בפועל. לצורך הפחתת ההשפעה של ערכי הקיצון המתקבלים מאחד או יותר מחמשת המודלים חושב רווח סמך עונתי, מותאם טמפרטורה. אמד שיא ביקוש של שיטת למידת מכונה הגבוהה או הנמוך מגבולות רווח הסמך אינו משפיע על אמד שיא ביקוש משוקלל של המודלים הנותרים. קביעת גבולות רווח הסמך נעשים על ידי התאמה דינמית המביאה בחשבון את התנאים המטאורולוגיים הצפויים ליום התחזית. לדוגמה, בעונת הקיץ, טמפרטורות מקסימליות גבוהות עשויות להצביע על פוטנציאל לעלייה בביקוש החשמל, המצריכה התאמה כלפי מעלה של רווח הסמך, בעוד שטמפרטורות נוחות עשויות להוביל לביקוש נמוך יותר, המצריך התאמה כלפי מטה. בעונת החורף, המוצגת על ידי משוואה מספר 2, טמפרטורות מינימום נמוכות מובילות לביקושי חשמל גבוהים יותר ולכן רווח הסמך מוטה כלפי מעלה. התאמה זו מגדילה את הגמישות במודל החיזוי, ומאפשרת התחשבות בגורמים חיצוניים משתנים על ידי רווח הסמך.

$$T_{Min}^{\circ C} \leq T$$

$$Upper Limit = Q_{3i} + \bar{P} \cdot Q_{3i}$$

$$T_{Min}^{\circ C} > T$$

$$Upper Limit = Q_{2i} + \bar{P} \cdot Q_{2i} \quad (2)$$

עבור $T - Q_{2i}$ טמפרטורה מינימלית (Lower Limit) המנבא ביקוש Q_{2i} של גבול Q_{2i} על ידי Q_{2i} ורווח הסמך, Q_{1i} , Q_{3i} – האחוזונים ה-25, ה-50 וה-75 בהתאמה של חמשת תוצאות האומדנים ביום i .

ממשוואה מספר 2 ניתן לראות כי חישוב רווח הסמך נקבע על ידי האומדנים המתקבלים מחמשת השיטות השונות והכפלה באחוז הנקבע על פי מקדם רווח הסמך (P) הקובע את רוחב גבולות הסמך. בעונת החורף, כאשר הטמפרטורות המינימליות נמוכות מערך T הגבול העליון נקבע על פי האחוזון ה-75 של תוצאות המודלים ולכן הוא מוטה כלפי מעלה. כאשר הטמפרטורות המינימליות גבוהות מערך T הגבול העליון נקבע על ידי חציון תוצאות המודלים ולכן הוא נמוך יותר.

מקדם רווח הסמך מחושב בעזרת תהליך אופטימיזציה יומי. בתהליך נבחן בכל יום מהו הערך בו גבולות הסמך כוללים בתוכם תחזיות שהממוצע שלהן הוא הקרוב ביותר לשיא הביקוש שנמדד בפועל. המקדם מחושב על ידי הממוצע העונתי עד היום הקודם של הערכים האופטימליים שהושגו. מתודולוגיה זו מבטיחה רווח סמך המותאם בצורה מיטבית לתחזיות הביקוש, תוך שיפור הדיוק והפחתת הטיית פוטנציאליות.

2.5 קביעת ערך האומדן:

אומדן שיא הביקוש נקבע בעזרת המודלים הנמצאים בגבולות רווח הסמך. בכדי לקבוע את השפעת האומדנים המתקבלים על הערך הסופי נדרש לחשב את המשקל המתאים לכל מודל. משקול האומדנים מתבצע בשני שלבים, חישוב ממוצע שגיאות היסטורי למודל (החל מ-1 בינואר 2017 ועד יום התחזית) ובחירת הימים הקרובים מטאורולוגית ליום התחזית, המשמשים לקביעת ממוצע השגיאות. במשוואה מספר 3 מוצגת נוסחת שגיאת האומדן במודל k , ביום i לשיא הביקוש MD. הממוצע מחושב על פי ערך ה-APE (Absolute Percentage Error).

$$APE_{ik} = \left| \frac{\overline{MD_{ik}} - MD_i}{MD_i} \right| \quad (3)$$

קביעת הימים הנבחרים: בכל יום נבחרים הימים הדומים ביותר ליום החיזוי, בהתבסס על נתונים מטאורולוגיים (טמפרטורות, לחות, עומסי חום, גשמים ועוד) ומאפייני זמן (חודש, סוג יום). בממוצע נבחרים כ-25 ימים.

ערך משקל כל מודל מחושב על ידי ערכי ה-APE המתאימים לו בימים הנבחרים. ככל שהיום הנבחר קרוב יותר במאפייניו ליום החיזוי, המשקל של ה-APE גבוה יותר. המשקל של כל מודל נקבע על ידי התוצאות המנורמלות של כלל הממוצעים המשוקללים. באופן זה הקצנו משקל רב יותר לתוצאת חיזוי של מודלי למידת מכונה שהניבו תוצאות מדויקות יותר בימים דומים ליום אותו אנו רוצים לחזות.

3. תוצאות המחקר

בכדי לבחון את טיב המודלים אנו משתמשים בארבעה מדדי דיוק. מדדים אילו פותחו בכדי לבחון את המודלים בהתאם לנושאים החשובים לחברת נגה, מנהלת מערכת החשמל בישראל.

1. APE המוצג במשוואה מספר 3

2. Adjusted MAPE – מדד זה המוצג במשוואה מספר 4, הינו MAPE מותאם לצורכי מערכת החשמל, בו ניתן משקל שונה לשגיאה החצי שעתית הממוצעת. משקל גבוה לסטייה (ענישה) מתקבל בשעות בהן הצריכה גבוהה ובשעות בהן ייצור ה-PV קטן מאוד אך ביקושי החשמל עדיין גבוהים (21:00 – 17:00). שעות אלו מקבלות את המשקל המקסימלי בין 0.85 למשקל שקיבלו בהתאם למרחק משיא הביקוש. בנוסף, העלות של תחזית נמוכה מהביקוש בפועל (אמידת חסר) גבוהה מהעלות של תחזית גבוהה מהביקוש בפועל (אמידת יתר) ולכן בימים בהם יש אמידת חסר הגדלנו את ערך השגיאה ב-10%.

$$Adj. MAPE_i = \quad (4)$$

$$\begin{cases} \frac{\widehat{D}_{ij} - D_{ij}}{D_{ij}} \cdot \max\left(\frac{D_{ij} - \min(D_i)}{\max(D_i) - \min(D_i)}, 0.85\right), & \text{if } 17:00 \leq \text{Hour} \leq 21:00 \text{ and } \widehat{D}_{ij} > D_{ij} \\ 1.1 \cdot \frac{|\widehat{D}_{ij} - D_{ij}|}{D_{ij}} \cdot \max\left(\frac{D_{ij} - \min(D_i)}{\max(D_i) - \min(D_i)}, 0.85\right), & \text{if } 17:00 \leq \text{Hour} \leq 21:00 \text{ and } \widehat{D}_{ij} \leq D_{ij} \\ \frac{\widehat{D}_{ij} - D_{ij}}{D_{ij}} \cdot \frac{D_{ij} - \min(D_i)}{\max(D_i) - \min(D_i)}, & \text{if Hour} < 17:00 \text{ and Hour} > 21:00 \text{ and } \widehat{D}_{ij} > D_{ij} \\ 1.1 \cdot \frac{|\widehat{D}_{ij} - D_{ij}|}{D_{ij}} \cdot \frac{D_{ij} - \min(D_i)}{\max(D_i) - \min(D_i)}, & \text{if Hour} < 17:00 \text{ and Hour} > 21:00 \text{ and } \widehat{D}_{ij} \leq D_{ij} \end{cases}$$

עבור ביקוש D ביום i ובשעה j .

3. Threshold Rate – מדד זה הוא ממוצע כמות הפעמים בו כל תחזית מבין 48 חצאי השעות היומיות סוטה מעבר ל-500 מגה-וואט, הספק ממוצע של תחנת כח, ביחס לערך האמיתי בנקודת הזמן הנבחנת. המדד מחושב בעזרת אינדיקטור (I) המקבל את הערך 1 אם הפער בין התחזית לביקוש בפועל עולה על 500 מגה-וואט ו-0 אחרת, כפי שמתואר במשוואה מספר 5.

$$Threshold Rate_i = \frac{\sum_{j=1}^n \mathbb{I}(|\widehat{D}_j - D_j| > 500)}{n} \quad (5)$$

עבור יום i וחצי שעה j מתוך $n = 48$ חצאי השעות ביום.

4. Adjusted Threshold Rate – מדד זה הינו התאמה של מדד **Threshold Rate** לשיא הביקוש המחושב על פי ממוצע כמות הפעמים בו כל תחזית מבין 48 חצאי השעות היומיות סוטה מעבר ל-500 מגה-וואט ביחס לערך שיא הביקוש ביום מסוים. המדד מתואר במשוואה מספר 6.

$$\mathbb{I}_{Adj.Threshold Rate}(i) = \begin{cases} 1, & \text{if } \left| \frac{\widehat{D}_i - D_i}{D_i} \right| \geq \frac{500MW}{MD_i} \\ 0, & \text{if } \left| \frac{\widehat{D}_i - D_i}{D_i} \right| < \frac{500MW}{MD_i} \end{cases} \quad (6)$$

$$Adj.Threshold Rate = \frac{1}{N} \sum_{i=1}^N \mathbb{I}_{Adj.Threshold Rate}(i)$$

עבור ביקוש D ביום i וחצי שעה j ושיא הביקוש MD מתוך $N = 48$ חצאי השעות ביום.


מדדי הדיוק בוחנים את ערכי השגיאות של אמידת שיא הביקוש ביחס לביקוש בפועל. ככל שהם נמוכים יותר הם מדויקים יותר. בטבלה מספר 1 מוצגים ערכי המדדים עבור שיא הביקוש בחודש אוגוסט 2024. ניתן להבחין שממוצע האומדן המשוקלל מדויק מאומדן הממוצע הפשוט. כמו כן, מודלים מסוימים יכולים להיות טובים יותר במדד מסוים ופחות באחר. דוגמה מספר 1 מתארת גרפית את המרחק בין אומדן שיא הביקוש המשוקלל לשיא הביקוש בפועל בחודש הנבחן. בדוגמה מספר 2 מוצגת עקומת הביקוש ביום נבחר (26/08/2024), כפי שמועברת בכל יום לחזאי עקומת הביקוש המשקית בחברת נגה.

טבלה מספר 1: תוצאות של מדדי הדיוק של ממוצע שיא הביקוש בחודש אוגוסט 2024 עבור כלל המודלים השונים, ערכם הממוצע והממוצע המשוקלל.

Measures	RF	MLP	SVR	XGB	LSTM	Mean	Weighted prediction
APE	2.27%	2.33%	2.23%	2.37%	2.65%	2.10%	2.07%
Adjusted MAPE	1.18%	1.22%	1.16%	1.26%	1.46%	1.09%	1.07%
Threshold Rate	10.96%	13.20%	12.64%	15.08%	18.78%	9.85%	8.94%
Adjusted Threshold Rate	18.02%	20.53%	20.25%	21.16%	27.09%	16.69%	14.94%


דוגמה מספר 1: תחזית ממושקלת של שיא הביקוש בהשוואה לביקוש בפועל בחודש אוגוסט 2024.

הנקודות הכחולות מייצגות את ערכי שיא הביקוש האמפיריים והנקודות הירוקות הינן הערכים הנאמדים (ערכים משוקללים). ניתן לראות שבמרבית הימים ישנה התאמה בין שני הערכים.



דוגמה מספר 2: עקומת ביקוש יומית (26/08/2024)

הקווים הכחולים הינם רווחי הסמך העליונים והתחתונים והקו הכתום הוא האומדן המשוקלל. השטח הכחול הבהיר תחת העקומה מייצג את ערך הביקוש האמיתי.



4. סיכום

בעבודה זו הוצג שימוש במודלים של למידת מכונה ככלי לאמידת שיאי ביקוש יומיים בחשמל. לעבודה מספר יתרונות. העבודה מאפשרת דיוק גבוה בתחזיות והתמודדות עם משתנים רבים בעזרת ניתוח כמויות גבוהות של נתונים היסטוריים כמו צריכת חשמל, תנאי מזג אוויר, התנהגות משתמשים וזיהוי תבניות נסתרות. המודל המוצע מאפשר גמישות רבה לשינויים בנתונים עיתיים והתייחסות למגמות משתנות בצריכת החשמל. תחזיות מדויקות של שיאי ביקוש מאפשרות למנהל המערכת לשמור על איזון בין היצע וביקוש ולהימנע ממצבים של מחסור או עודף אנרגיה. הן מסייעות לייעל את תכנון הייצור, להפחית בזבז משאבים ועלויות תפעול ובשמירה על יציבות הרשת.

מבין חמש שיטות שונות המייצרות חמישה אומדנים לשיא הביקוש, נבחרים בכל יום האומדנים שאינם חריגים. כל אחד מהאומדנים הנבחרים ממושקל בעזרת מידת הדיוק ההיסטורית של אומדן המודל לערך שיא הביקוש האמיתי ופונקציית מרחק בין מאפייני היום הנחזה ליום ההיסטורי הנבחר. המודל פותח ביחידת החיזוי והמחקר הסטטיסטי בחברת נגה, מנהלת מערכת החשמל והינו מחקר מתמשך שמטרתו הינה דיוק אומדני שיא הביקוש ואפיון עקומת הביקוש החזויה לימים הקרובים. העבודה הינה יישומית ומשמשת ככלי עזר לחזאי עקומת הביקוש המשקית בישראל. תוצאות המודל ומידת דיוקו המוצגים במאמר, מצביעים על דיוק גבוה המאפשר שימוש בתוצאות המודל ככלי עזר לניהול משק החשמל.

תודות:

העבודה נעשתה בהדרכה של מחלקת משטרי תפעול ביחידת ניהול המערכת אשר הינם מומחי התוכן בתחום. תודה מיוחדת לאדוארד שקודוביץ' וברוך בולטנסקי על ההדרכה וההעמקה בכל מקרה בו נדרשנו להבין את התנהגות הצריכה המשקית ולתמיר לן מנהל המחלקה שתרם רבות להתממשות שיתוף הפעולה בין הגופים ולהוספת התובנות שהוזנו בתוך המודלים הסטטיסטיים.

ביבליוגרפיה:

- Abera, F. Z., & Khedkar, V. (2020). Machine learning approach electric appliance consumption and peak demand forecasting of residential customers using smart meter data. *Wireless Personal Communications*, 111(1), 65-82.
- Adnan, R. M., Liang, Z., Kuriqi, A., Kisi, O., Malik, A., Li, B., & Mortazavizadeh, F. (2021). Air temperature prediction using different machine learning models. *Indonesian Journal of Electrical Engineering and Computer Science*, 22(1), 534-541
- Aguilar Madrid, E., & Antonio, N. (2021). Short-term electricity load forecasting with machine learning. *Information*, 12(2), 50.
- Arumugam, K., Naved, M., Shinde, P. P., Leiva-Chauca, O., Huaman-Osorio, A., & Gonzales-Yanac, T. (2023). Multiple disease prediction using Machine learning algorithms. *Materials Today: Proceedings*, 80, 3682-3685.
- González-Briones, A., Hernández, G., & M, J. (2019). Machine learning models for electricity consumption forecasting: A review. *IEEE*.
- Guo, W., Che, L., Shahidehpour, M., & Wan, X. (2021). Machine-Learning based methods in short-term load forecasting. *The Electricity Journal*, 34(1), 106884.
- Haq, E. U., Lyu, X., Jia, Y., Hua, M., & Ahmad, F. (2020). Forecasting household electric appliances consumption and peak demand based on hybrid machine learning approach. *Energy Reports*, 6, 1099-1105.
- Lee, J., & Cho, Y. (2022). National-scale electricity peak load forecasting: Traditional, machine learning, or hybrid model?. *Energy*, 239, 122366.
- Mosavi A, Ozturk P, Chau K-w. Flood Prediction Using Machine Learning Models: Literature Review. *Water*. (2018); 10(11):1536.

יצחק (איציק) יוסף, ענת בהר"ד, לינס אוזן, איזבלה אוסטינסקי-צדקי, יצחק כרמונה, נועם חלפון, אבנר פורשפן, יואב לוי, ניר סתיו. (2019). שינוי האקלים בישראל מגמות עבר ומגמות חזויות במשטר הטמפרטורות והמשקעים דו"ח מחקר מס', 4000-0804-2019-, 0000075.