



דו"ח סיכום על מחקרנו שנושא:

## **התאמת מודלים סטטיסטיים לניתוח מגמות תאונות הדרכים בישראל**

המחקר ממומן על ידי:

**קרן המחקרים בענייני ביטוח ליד אגוד חברות הביטוח בישראל**

מאת: פרופ/ח אילה כהן וד"ר אטי דובא

המעבדה לסטטיסטיקה

הפקולטה להנדסת תעשייה וניהול

ד"ר ויקטוריה גיטלמן

מרכז רן נאור לחקר הבטיחות בדרכים

## הסבר על מבנה הדו"ח המוגש הכולל שני חלקים

מטרת מחקר זה הייתה לפתח שיטות סטטיסטיות המבוססות על הכלים הסטטיסטיים המעודכנים ביותר לניתוח מגמות תאונות הדרכים. בפרט, שיטות אשר תענינה על השאלות האם בהשוואה בין תקופה "אחרונה", כמו למשל שנה או שנתיים אחרונות לעומת תקופה מסוימת קודמת הכוללת מספר שנים, חל שינוי מובהק במגמה של מספר ההרוגים והאם היה שינוי מובהק במספר ההרוגים.

בדיווח ממצאי מחקר כזה יש להתייחס לשני סוגי קוראים. הסוג האחד צריך להיות ברמת ידע גבוהה בסטטיסטיקה כדי להבין את כל המושגים, בפרט כשמחקר כזה אמור להתבסס ולהשתמש בשיטות סטטיסטיות חדשניות. מצד שני, מטרת מחקר כזה היא לבנות כלי שיענה על שאלות מעשיות בעלות חשיבות למקבלי החלטות בנושאי תחבורה. לכן, ראינו צורך בדיווח גם לסוג הקוראים שאינו מעוניין בפרטי הצדדים הטכניים אלא במסקנות העיקריות. לסוג זה של קוראים תועד החלק שקראנו לו "דו"ח מנהלים", אשר כולל מעט פרטים טכניים אך בעיקרו הוא מהווה סיכום מסקנות. לסוג הקוראים הראשון אמור הדו"ח המפורט של מחקר זה לסייע כמדריך למחקרים נוספים בנושאי תחבורה, שבהם ייחקרו שינויים לאורך זמן.

הדו"ח המוגש עתה מסכם את המחקר שבו סקרנו שיטות חדשניות לניתוח נתוני מנייה. בחלק הראשון של המחקר אשר תועד גם בדו"ח הביניים שהוגש למזמין העבודה מתוארות שיטות אשר יושמו על 13 סדרות של נתונים על הרוגים בתאונות הדרכים בישראל. החלק השני של המחקר, דן בשיטות של תרשימי בקרה ושילובם בניתוח סדרות זמן של מנייה כאמצעי מעקב על ההשתנות בזמן של סדרות מסוג זה. השיטות יושמו על 3 סדרות נתונים של הרוגים בתאונות דרכים. הדו"ח כולל פירוט של השיטות, הדגמת יישומן על הסדרות וכן את מסקנות הניתוח שבו יושמו השיטות על סדרות אילו.

עבודת מחקר זו הייתה בהיקף מאד רחב. עיון בכל הממצאים עלול להיות בלתי מעשי ומיותר. לפיכך, בחרנו שלא לפרט כמו שפרטנו בדו"ח הביניים אשר סיכם ממצאי חלק ראשון בלבד. בדו"ח סיכום זה יוצגו ממצאים שנראו לנו מעניינים ומספיקים לקורא. המעוניינים יוכלו לקבל מאתנו את כל פלטי הניתוחים לכל סדרה שנותחה.

## תוכן עניינים

5	דו"ח המנהלים
5	הקדמה
6	חלק ראשון - בחינת שינוי במגמה ובקצב התאונות
6	הנתונים
7	המודלים המתאימים
7	בחינת שינוי במגמה
8	בחינת שינוי ממוצע בקצב המופע היומי של התאונות
9	סיכום חלק ראשון
9	חלק שני - תרשימי בקרה (CONTROL CHARTS)
9	מבוא
10	בקרת איכות רב-ממדית
11	בדיקת מגמות בתאונות הדרכים החמורות עבור השנים האחרונות בעזרת תרשימי בקרה
12	סיכום חלק שני
14	דו"ח המפורט
14	הסבר על הדו"ח המפורט
15	הקדמה
16	חלק ראשון - בחינת שינוי במגמה ובקצב התאונות
16	1. ניתוח סדרות עיתיות של נתוני מנייה
16	1.1 כללי
18	1.2 סיווג מודלים לסדרות עיתיות של נתוני מנייה
18	1.2.1 מודלים מונעי תצפיות (observation driven) לעומת מודלים מונעי פרמטרים (parameter driven)
20	1.2.2 מודלים מותנים (conditional) לעומת שוליים (marginal)
22	1.2.3 מודלים נוספים לסדרות עיתיות של נתוני מנייה
24	2. סקירת שלבי ניתוח סדרות ההרוגים בתאונות
24	2.1 שלב א: התאמת מודל מנייה ראשוני (עם התעלמות מתלות אפשרית) לסדרות המנותחות
26	2.2 בחינת תלות הנתונים
27	3. ניתוח סדרות ההרוגים בתאונות
27	3.1 הסדרות שנתחו
28	3.2 שלב א: התאמת מודל מנייה ראשוני (עם התעלמות מתלות אפשרית) לסדרות המנותחות
28	3.2.1 רשימת המשתנים המסבירים
29	3.2.2 ערכי המשתנים המסבירים
31	3.2.3 נתונים תאוריים והיסטוגרמות עבור 13 הסדרות
32	3.2.4 תוצאות התאמת שלושת המודלים והשוואתם - לכל סדרה בנפרד
33	3.2.5 מסקנות

33	.....	3.3.3. ניתוח סדרות השאריות מהמודלים שנבחרו
33	.....	3.3.3.1. הפלטים עבור 13 הסדרות
37	.....	3.3.2. מסקנות מניתוח שאריות המודלים
<b>37</b>	.....	<b>4. התאמת מודלים עם אפשרות לתלות בנתונים</b>
37	.....	4.1. השיטה
39	.....	4.2. פלטים
43	.....	4.3. מסקנות
<b>43</b>	.....	<b>5. בחינת שינוי במגמה ובממוצע התאונות</b>
43	.....	5.1. רקע
43	.....	5.2. בחינת שינוי במגמה
46	.....	5.2.1. פלטים
49	.....	5.3. בחינת שינוי ממוצע קצב המופע היומי של התאונות
52	.....	5.3.1. פלטים
61	.....	5.3.2. מסקנות לגבי שינוי הקצב
<b>61</b>	.....	<b>סיכום חלק ראשון</b>
<b>62</b>	.....	<b>חלק שני - תרשימי בקרה (CONTROL CHARTS)</b>
<b>62</b>	.....	<b>6. התפתחות שיטות סטטיסטיות לצרכי בקרת התהליכים</b>
62	.....	6.1. רקע מהספרות
64	.....	6.2. בקרת איכות רב ממדית
65	.....	6.3. שימוש בתרשימי בקרה למעקב בתאונות דרכים (סקר ספרות)
69	.....	6.4. יישום השיטות הסטטיסטיות של תרשימי בקרה במחקר זה
<b>70</b>	.....	<b>7. בדיקת מגמות בתאונות הדרכים החמורות, בשנים האחרונות, בעזרת תרשימי בקרה</b>
70	.....	7.1. כללי
70	.....	7.2. הצגת הסדרות שתנותחנה
71	.....	7.3. תרשימי SHEWHART, CUSUM ו- EWMA חד-ממדיים של הסדרות
71	.....	7.3.1. הקדמה
71	.....	7.3.2. תרשים Cusum
71	.....	7.3.3. תרשים ה- EWMA
72	.....	7.3.4. התרשימים שנבנו והמסקנות
77	.....	7.4. תרשימי SHEWHART, CUSUM ו- EWMA רב-ממדיים
78	.....	7.4.1. הצגת הסדרות שתנותחנה
78	.....	7.4.2. תרשים ה- Shewhart הרב-מימדי
78	.....	7.4.3. תרשים ה- MCUSUM
78	.....	7.4.4. התרשימים שנבנו
<b>82</b>	.....	<b>סיכום חלק שני</b>
<b>84</b>	.....	<b>מראי מקום</b>

# דו"ח המנהלים

## הקדמה

הסדרות של נתוני תאונות דרכים בהן עוסק מחקר זה הינן סדרות עיתיות (time series), מהסוג הנקרא נתוני מנייה (count data). אלה נתונים שלמים אי-שליליים שהם בסדרי גודל קטנים יחסית. נתונים מסוג זה מופיעים בשלושים השנים האחרונות במגוון רחב של תחומים, ולכן נוצר צורך בפיתוח שיטות לניתוח סדרות כאלו.

במחקר זה בוצע חקר ספרות על השיטות החדשניות שפותחו לניתוח נתוני מנייה, וליישומן של שיטות אלה לניתוח סדרות של נתונים שונים על הרוגים בתאונות דרכים. בשלב ראשון, אשר ממצאיו פורסמו בדו"ח הביניים, נתוני 2010 לא היו זמינים ולכן הניתוחים בוצעו עבור 13 סדרות שכללו חתכים שונים של נתוני הרוגים ב-6 השנים 2003-2008. המחקר בשלב השני עסק בתיאור שיטות של תרשימי בקרה עבור נתוני מנייה. יישום שיטות אלה בוצע על 3 סדרות נתוני הרוגים מתאונות דרכים אשר כללו את השנים 2005-2010.

בחקר הספרות על ניתוח נתוני מנייה (שלא כולל תרשימי בקרה), מצאנו במגוון שטחים יישומים שבהם יושמו השיטות השונות, חלקם בתחום של ניתוח נתוני תאונות, ובפרט תאונות דרכים שהוא התחום בעל העניין במחקר זה. דוגמאות בתחומים אחרים היו: בקרימינולוגיה (לדוגמה: האם שינוי בחוקי ענישה מביא לירידה במספר מקרי פשע); בתיירות (לדוגמה: האם השקעה באתר תיירות הביאה לגידול במספר התיירים באתר); בבריאות וסביבה (לדוגמה: האם יש קשר בין רמת זיהום אוויר ומספר פניות לחדרי מיון עקב בעיות נשימה); בדמוגרפיה (לדוגמה: האם חל שינוי באוכלוסיות מסוימות במספר הילדים במשפחה); בשיווק (לדוגמה: האם היו שינויים לאורך זמן בצריכת מוצר מסוים על ידי צרכנים לאורך זמן והאם היה אפקט לפרסום על התנהגותם של הצרכנים).

הדו"ח משקף את פרי עבודת חקר הספרות שבעקבותיו נבחרו השיטות אותן מצאנו כיותר מתאימות לניתוח נתוני תאונות הדרכים. בדו"ח מובאת סקירת ספרות מפורטת על שיטות הניתוח של סדרות זמן לנתוני מנייה וביניהן השיטות שבחרנו לניתוח נתוני תאונות הדרכים. בין השיקולים שהביאו לבחירתנו היה מידת התאמתן לאופי סדרות אלה. שיקול לוגיסטי נוסף היה זמינות תוכנה לביצוען ופשטות יחסית של השימוש בתוכנה. הפרוצדורה שהשתמשנו בה הייתה GLIMMIX מחבילת התוכנה SAS. מצאנו שפרוצדורה זו נותנת מענה הולם לשאלות שלמטרת פתרון בוצע הניתוח.

ממצאי הניתוחים שהתקבלו על בסיס יישום השיטות על סדרות הרוגים מובאים בדו"ח זה.

נזכיר כי מטרת הניתוח הייתה לבדוק:

- האם מגמת הבטיחות (safety) עבור הרוגים/ נפגעים בתקופה "אחרונה" השתנתה באופן מובהק לעומת המגמה בתקופה הקודמת?

- האם הבטיחות עבור הרוגים/ נפגעים בתקופה "אחרונה" שונה באופן מובהק מהבטיחות בתקופה הקודמת?

אילו שתי שאלות שונות שכן הרמה יכולה להשתנות אך לא קצב השינוי.

במושג "בטיחות" אנו מתכוונים לתוחלת מספר האירועים היומי. לכן, "בטיחות" עבור הרוגים/ נפגעים הינה תוחלת מספר ההרוגים/ הנפגעים היומי.

השלב השני במחקר שעליו לא דווח בדו"ח הביניים עסק בתרשימי בקרה כאמצעי לבדיקה האם התהליך של מספר ההרוגים/ התאונות/ הנפגעים בשנה השוטפת נשאר בבקרה סטטיסטית, כאשר הבחינה מתבצעת באמצעות תרשימי הבקרה.

הדו"ח בנוי כך שחלקו הראשון כולל את מה שפורסם בדו"ח הביניים ודן בשיטות השונות שאינן כוללות תרשימי בקרה. מתואר יישום שיטות אלה על 13 סדרות ההרוגים של 6 השנים 2003-2008.

החלק השני מתאר שיטות של תרשימי בקרה, ויישומן על 3 סדרות הרוגים של 6 השנים 2005-2010.

## **חלק ראשון - בחינת שינוי במגמה ובקצב התאונות**

### **הנתונים**

הסדרות עליהן בוצעו הניתוחים הסטטיסטיים הן סדרות חודשיות של הרוגים בתאונות, בתקופה מ-1/2003 עד 12/2008 (סה"כ בשטח מדינת ישראל, לא כולל יו"ש). כמקור הנתונים שימשו קבצי תאונות הדרכים של הלמ"ס, כאשר מספרי ההרוגים היו בהתאם להגדרה של הרוג בתאונה (נפטר תוך שלושים יום מתאריך התאונה).

הניתוח כלל 13 סדרות של נתונים שהן:

1. סה"כ מספר ההרוגים
2. מספר הרוגים בדרכים לא עירוניות
3. מספר הרוגים בדרכים עירוניות
4. מספר הרוגים בתאונות עם נהגים צעירים (לפחות אחד מהנהגים המעורבים בתאונה הוא נהג צעיר בגיל 17-21)
5. מספר הרוגים בתאונות עם רכב מקצועי (לפחות אחד מכלי הרכב המעורבים בתאונה הוא רכב משא מעל 4 טון)
6. מספר הרוגים בתאונות רכב דו-גלגלי (לפחות אחד מכלי הרכב המעורבים בתאונה הוא אופנוע)
7. מספר הרוגים הולכי רגל בדרכים העירוניות
8. מספר הרוגים הולכי רגל בדרכים הלא עירוניות
9. מספר הרוגים הולכי רגל במגזר הלא יהודי (קבוצת אוכלוסייה: "ערבים ואחרים", לא כולל "זרים")
10. מספר הרוגים בתאונות רכב בודד בדרכים הלא עירוניות
11. מספר הרוגים בתאונות חזית-חזית בדרכים הלא עירוניות
12. מספר הרוגים בצמתים לא עירוניים (פרט לתאונות הולכי רגל)
13. מספר הרוגים בצמתים עירוניים (פרט לתאונות הולכי רגל)

בניתוח הסטטיסטי שבו יושמה השיטות בוצעו שתי השוואות. האחת, בין תקופה "אחרונה" (שנת 2008) לעומת תקופה קודמת, של השנים 2003-2007. השנייה, בין אותה תקופה "אחרונה" (שנת 2008), לעומת תקופה קודמת שכללה רק את שנת 2007.

### **המודלים המתאימים**

לבצוע ההשוואות היה צורך להתאים מודל שיתאר עבור כל סדרה את השתנותה כפונקציה של משתנים מסבירים. תרומת מחקר זה היא בהתאמת מודל שאינו בהכרח מניח התפלגות פואסונית, וכן יישום שיטות המתחשבות באפשרות של קיום תלות בין תצפיות הסדרה.

שלב ראשוני בבניית המודלים היה התאמת מודל מנייה תוך התעלמות מתלות אפשרית. התאמה זו מקובלת כנקודת הפתיחה בהתאמת סדרות עיתיות לנתוני מנייה. על בסיס ניתוחים קודמים, ידוע שקיימת עונתיות וכן מגמה ליניארית בסדרות אלה. לפיכך, כללנו כמשתנים מסבירים במודלים - מגמה ליניארית וזוגות של סינוסים וקוסינוסים בתדירויות שנתיות וחצי-שנתיות. מכיוון שמספר הימים בכל חודש שונה, נכלל גם משתנה  $offset$  השווה ללוג מספר הימים בחודש. (  $offset$  הינו משתנה מסביר שהמקדם שלו במודל נקבע להיות שווה ל-1). התקופה שאליה מתייחסות סדרות הנתונים במחקר זה, כוללת את הזמן שבו התחוללה מלחמת לבנון השנייה. בגלל המלחמה, נגרם שינוי שאותו היה צורך לקחת בחשבון במודלים. הדבר נעשה על-ידי יצירת משתנה אינדיקטור שכונה בשם  $WAR$ , המקבל את הערך 0 בחודשים שאינם חודשי מלחמה וערך השווה ל-1 בחודשי המלחמה (דהיינו, בחודשים 7/2006 ו-8/2006). משתנה זה נכלל גם הוא כמשתנה מסביר במודלים.

לכל סדרה בדקנו מהי ההתפלגות המתאימה מבין מספר התפלגויות המתאימות לתיאור נתוני מנייה. הבחירה הייתה בין ההתפלגות הפואסונית, פואסונית עם  $(NB1)$  dispersion, ובינומית שלילית  $(NB2)$ . בדיקת טיב ההתאמה של כל אחד ממודלים בוצעה בשתי דרכים: האחת פורמאלית המשווה בין התפלגות פואסונית לבין  $NB1$  וגם  $NB2$ , ואילו השנייה גרפית.

על בסיס בדיקה זו הסקנו שפרט לסדרות 2, 5, 12, שעבורן ההתפלגות המתאימה הייתה הבינומית השלילית, לכל שאר 10 הסדרות התאימה ההתפלגות הפואסונית.

לאחר שלב ראשון של בחירת מודל המתאים לכל סדרה, כאשר הבחירה נעשתה ללא התחשבות בתלות הנתונים, חושו מספר סוגי שאריות מהמודל לבחינת התלות בסדרה, וצורתה (אם קיימת בנתונים). המסקנה שקיבלנו הייתה שברוב הסדרות האלה, המשתנים המסבירים אכן מתאימים למודל, ובהינתן משתנים אלה התלות בין תצפיות המודל נעלמת כמעט לחלוטין. רק בשלוש סדרות: 3, 5, 11 - נמצאה מובהקות גבולית במבחן ההשערה שיש אי-תלות.

בהמשך, נעשתה בחינת מובהקות השינויים עבור 13 הסדרות. השאלה לגבי כל סדרה לחוד, הייתה האם חלו בסדרה שינויים במגמה או/ו ברמה בשנת 2008, בהשוואה לתקופה קודמת שהייתה או 2003-2007, או רק 2007.

### **בחינת שינוי במגמה**

השוואת המגמה בין שתי התקופות בוצעה באופן הבא: לנתוני הסדרה שכללו את שתי התקופות יחד: "לפני" ו-"אחרי", דהיינו השנים 2003-2008, הותאם אותו המודל כמו זה אשר הותאם עבור התקופה

"לפני". אולם, הפעם נוספו עוד שני משתנים מסבירים: משתנה המלחמה בעזה ומשתנה שינוי מגמה לחודשים של שנת 2008. מקדם משתנה שינוי המגמה הוא ההבדל בין מקדם המגמה של התקופה לפני 2008 לעומת המקדם של 2008. מובהקות אמד מקדם רגרסיה זה מעידה על שינוי מגמה.

הותאמו מספר סוגי מודלים השונים ביניהם בצורת התחשבותם בתלות הסדרתית האפשרית בנתונים. האחד היה מהסוג הידוע: כמודל מותנה שהוא המודל של (Davis & Wu (2009). כמו כן, כללנו שני מודלים מהסוג הידוע כמודלים שוליים. כאשר בוצעה התאמת המודלים **השוליים** להתפלגות בינומית היו בעיות חישוביות. (לא הייתה כל בעיה בהתאמת המודלים **המותנים** כאשר ההתפלגות המותאמת הייתה בינומית שלילית). לכן, בניתוח זה התאמנו מודל שולי בהנחה שההתפלגות השולית היא פואסונית עם תלות. בדקנו, בנוסף, מודל בינומי שלילי ללא תלות. עבור הסדרות 11, 13 לא התכנס אף מודל שלוקח בחשבון תלות.

פרט לסדרה 12 (שהיא: מספר הרוגים בצמתים לא עירוניים, פרט לתאונות הולכי רגל), בכל שאר הסדרות לא מצאנו שינוי מובהק במגמה. בסדרה זו נמצא שינוי בכיוון של ירידה.

תוצאות אלה דומות מאד לאילו שהתקבלו במחקר קודם של גיטלמן ודובא (2009), אשר בו הניחו אי תלות בנתוני הסדרות. הדמיון אינו מפתיע לאור העובדה שהמחקר הנוכחי הראה כי בסדרות אילו יש הצדקה אמפירית להנחת אי-התלות בין התצפיות.

### **בחירת שינוי ממוצע בקצב המופע היומי של התאונות**

בהמשך בוצעו ההשוואות שנועדו לענות על השאלה: האם היה שינוי מובהק ברמה בין שתי התקופות ("לפני" לעומת "אחרי"). שינוי זה נבדק על-ידי השוואת הממוצעים הגיאומטריים של תוחלת קצב המופע היומי של התאונות בשתי התקופות.

ברוב הסדרות לא נמצא שינוי מובהק סטטיסטית בקצב הממוצע. ממצא זה אינו מפתיע שכן נתוני הסדרות יחסית קטנים ולכן עוצמת המבחנים הסטטיסטיים אינה גדולה, בפרט כשהשוואה היא בין שתי שנים. ההבדלים המובהקים שנמצאו היו עבור הסדרות שבהן המספרים היו גדולים יחסית (לא התייחסו לקטגוריות פרטניות). לכן, ראינו תוצאה מובהקת סטטיסטית (של ירידה) כאשר ההשוואה הייתה בין השנים 2003-2007 לבין 2008 בסדרה 1 שכללה את סה"כ מספר הרוגים ובסדרה 2 של סה"כ מספר הרוגים בדרכים הלא עירוניות. עבור שתי סדרות אלה התקבלה תוצאה מובהקת הן בניתוח שבו הייתה הנחת אי-תלות והן בניתוחים שבהם נלקחה בחשבון אפשרות התלות. בשני המקרים המובהקות שהתקבלה הייתה גדולה יותר (Pvalue קטן יותר) כאשר הייתה הנחת אי-תלות.

פרט לשתי הסדרות שכללו מספרים גדולים יחסית, גם בסדרה 12 של מספר הרוגים בצמתים לא עירוניים (פרט לתאונות הולכי רגל), מצאנו תוצאה מובהקת סטטיסטית של ירידה משמעותית גדולה יחסית בקצב, הן בהשוואה של השנים 2003-2007 מול 2008 והן בהשוואה של 2007 מול 2008.

כצפוי, היו הבדלים קטנים מאד בין הממצאים על בסיס המודלים "הפשטניים" שהתבססו על הנחת אי תלות לעומת המודלים האחרים. שכן התלות שמצאנו ב-13 הסדרות לא הייתה חזקה יחסית.



## סיכום חלק ראשון

תרומתה העיקרית והמשמעותית של עבודה זו אינה רק במסקנות הניתוח המתייחסות לסדרות של ההרוגים בשנים 2003-2008 שבו בחנו את השינוי ב-2008. התרומה המשמעותית היא בעיקר בהצגת הסבר מפורט על השיטות העדכניות שאותן מומלץ לאמץ במחקרים עתידיים שמטרתם בחינת שינויים בסדרות מסוג זה.

## **חלק שני - תרשימי בקרה (Control Charts)**

### מבוא

תחומי מחקר שונים עוסקים בשאלה כיצד לגלות שינויים בתהליך. השיטות הסטטיסטיות אשר פותחו ואשר עדיין ממשיכים לפתח משמשות לא רק בתחום של סטטיסטיקה תעשייתית ככלי לבקרת איכות של תהליכי ייצור, אלא בתחומים רבים ומגוונים, כמו זיהוי התפשטות מחלות (Bio-surveillance), גילוי מקרי תרמית (Fraud Detection) וכן, שינויי מגמות במעקב אחרי תאונות דרכים, שזה הנושא בעל העניין בעבודה זו. תרשימי הבקרה פותחו כאמצעי בקרת איכות בתהליכי ייצור. ההנחה הבסיסית בתרשימים אלה היא שבתהליך יציב אשר אינו מושפע ע"י גורמים מפריעים באופן שיטתי, כמות הפגמים במוצרי התהליך תישאר נמוכה - בגבולות של סטייה מקרית; במידה ומספר המוצרים הפגומים עולה (בתקופה מסוימת) בצורה משמעותית, תופעה זו אמורה להצביע על קיום גורם שיטתי מפריע אשר התערב בתהליך.

תפיסה זו קרובה להבנת תהליך התרחשות התאונות בשטח, כאירועים אקראיים, אך גם מושפעים על-ידי גורמים מערכתיים רבים. לפיכך, כבר משנות ה-1960 נעשו ניסיונות ליישם תרשימי בקרה למטרות אופרטיביות של ניהול הבטיחות בדרכים. בעבודות שפורסמו בשנות ה-1960 הוצעו בעיקר כלים מתמטיים ליישום תרשימי בקרה בתחום הבטיחות בדרכים (Fisher, 1970; Fisher and Moser, 1968). השימוש בכלים אלה לא אומץ באותה תקופה, כפי הנראה עקב מחסור בבסיסי מידע רלוונטיים וכן, בכלים ממוחשבים זמינים להפעלת כלים אלה. בעשורים הבאים, להערכת שינויים אומצה הגישה של שימוש במודלים, בדומה לגישתנו בחלקה הראשון של עבודה זו. בשנות ה-1990, בעקבות המהפכה בתחום המחשבים וזמינות תוכנות סטטיסטיות, החלו ליישם את רעיון תרשימי הבקרה לצורכי ניהול הבטיחות.

סיבה אפשרית נוספת להפניית תשומת הלב לכלי הבקרה הינה שינוי תפיסת בעיית הבטיחות בדרכים שהתרחש במדינות רבות בעשורים האחרונים. כיום, מקובל לבחון את בעיית הבטיחות בדרכים במדינה כבעיה מערכתית, עם כל מרכיבי הניתוח והניהול הנדרשים לכך. בין היתר, תוצרי המודלים הסטטיסטיים עם גבולות לחיזוי המצב, משמשים את צרכי הרשויות המפקחות להערכת ההתקדמות של התוכניות הלאומיות לבטיחות בדרכים. כלומר, אופן בחינת נתוני התאונות מתקרב לשיטת תרשימי הבקרה.

השיטה הקלאסית למעקב אחרי תהליכים היא תרשימי הבקרה הנקראים על שם Shewhart. נקודות המתאימות לתוצאות בתהליך אשר נמצאות בתרשימים אלה מחוץ לגבולות הבקרה נחשבות כתוצאות חריגות. חשיבות קריטית בבניית התרשימים יש להגדרת גבולות הבקרה. גבולות "צרים מדי" מגדילים את הסיכוי ל- False Positive, בעוד גבולות ליברליים עלולים להביא לסיכוי גדול שתהליך אשר אינו בבקרה לא יאובחן ככזה (False Negative).

כהשלמה לתרשימים מסוג Shewhart פותחו התרשימים מסוג CUSUM (Cumulative Sums) וגם התרשימים מסוג EWMA (Exponential Weighted Moving Averages). רגישותם של תרשימים אלה גבוהה יותר מזו של תרשימי Shewhart לגילוי סטיות קטנות. תרשימי CUSUM מבוססים על ניטור סידרתי של סכום הסטיות של ערכי התהליך ממטרה. שימוש בתרשימים אלה מאפשר פיקוח בזמן אמיתי (real-time) על התהליך ומאפשר זיהוי של הדרדרות בתהליך שהיה בבקרה. ב-CUSUM שינויים בתהליך גורמים לשינוי הזווית של התרשים, בנקודה בה חל השינוי. אולם, תרשימי CUSUM איטיים בגילוי שינויים גדולים לעומת תרשימי Shewhart, וכן לא קל לפרש את התבניות הנוצרות על-ידי התרשימים האלה מאחר והסכומים המצטברים מתואמים (אינם בלתי תלויים). כפי שנראה בדוגמאות במחקר זה, יתרונם בהשוואה לתרשימי Shewhart קטן יחסית, בפרט כאשר משלימים את תרשימי Shewhart במבחנים משלימים כפי שהוצעו על ידי Nelson (1984). מומלץ להשתמש בתרשימי CUSUM **כתוספת** לתרשימי Shewhart, ובכך ניתן יהיה לגלות הן שינויים גדולים והן שינויים קטנים בתהליך.

תרשים מסוג EWMA הינו תרשים בקרה המשתמש בכל היסטוריית התהליך, אם כי לא במשקל זהה, אלא במשקל הדועך גיאומטרי. עבור תרשימי EWMA יש לקבוע את מידת השקלול של תצפיות העבר. ככל שמשקל זה גבוה יותר כך גדלה השפעת הנתונים ההיסטוריים. קיימות גישות שונות לקביעת משקל זה. גישה אחת של Hunter (1986), היא להשאיר את השיפוט למנתח התהליך. ישנה גישה אחרת, לפיה נקבע השקלול על-פי ARL (Average Run Length), שהוא תוחלת מספר הנקודות עד לגילוי שינוי בתהליך. רצוי כמובן שמספר זה יהיה קטן כאשר יחול שינוי וגדול כאשר אין למעשה שום שינוי.

מכיוון שתרשימי ה-EWMA מבוסס בכל נקודה, הן על ערך התהליך הנוכחי והן על ערכים קודמים, בדומה ל-CUSUM, הוא רגיש לשינויים קטנים במוצע התהליך ולא לשינויים גדולים אשר מגלים תרשימי Shewhart. כמו כן, בדומה ל-CUSUM, גם ב-EWMA קשה לפרש את התבניות הנוצרות ע"י התרשימים מכיוון שהסכומים המצטברים יכולים להיות מאוד מתואמים. גם עבור תרשימים מסוג EWMA, בדומה ל-CUSUM, יש הממליצים להוסיף לתרשימי מסוג Shewhart, כדי לאפשר גילויים גם של שינויים גדולים וגם של שינויים קטנים בתהליך.

### **בקרת איכות רב-ממדית**

לעתים קרובות נעשה מעקב על מספר משתנים סימולטנית. במעקב על תאונות דרכים, ראינו שהעניין הוא בבחינה סימולטנית של נפגעים בדרגות חומרה שונות ובסוגים שונים של דרכים. המשתנים שעליהם נעשה המעקב יכולים להיות תלויים או בלתי תלויים. הבעיה של מבחנים רבים ידועה בסטטיסטיקה. בכל מבחן סטטיסטי יכולה להיות טעות סטטיסטית (מסוג ראשון או שני), ולכן כאשר מבצעים מספר רב של מבחנים יש סיכוי גדול מאד שלפחות אחת המסקנות תהיה שגויה. שיטות סטטיסטיות מיוחדות פותחו במשך שנים רבות לטיפול במבחנים מרובים, וביניהן שיטות בבקרת איכות. במהדורה האחרונה (השישית) של ספרו הקלסי של Montgomery על בקרת איכות נכלל פרק על שיטות אלה.

בין היתר, פותחו הרחבות של תרשימי הבקרה לנתונים רב-ממדיים מסוג EWMA (MEWMA) - ראה Lowry et al, 1992) וכן מהסוג CUSUM (MCUSUM), וכמו במקרה החד-ממדי, מחקרים שונים שבוצעו להשוואתם הראו שאין הבדל משמעותי בין הביצוע של תרשימי רב-ממדי המבוסס על החלקה אקספוננציאלית לבין זה המבוסס על סכומים מצטברים - ראה Fricker et al (2008).

## בדיקת מגמות בתאונות הדרכים החמורות עבור השנים האחרונות בעזרת תרשימי בקרה

מחקר זה כולל ממצאים שהתקבלו בעזרת תרשימי הבקרה. התרשימים בוצעו עבור 3 מתוך 13 סדרות נתוני ההרוגים שבידינו וכן, על מספר סדרות סינטטיות, כאשר המטרה הייתה להסיק על רגישות התרשימים לשינויים בנתונים. התרשימים כללו את תרשימי Shewhart וכמו כן, את תרשימי CUSUM ו-EWMA. בנוסף, בחנו האם יש יתרון כלשהוא בבקרה באמצעות תרשימי Shewhart ו-CUSUM רב-ממדיים.

3 הסדרות שנותחו הן:

(1) סה"כ הרוגים בתאונות, (2) סה"כ הרוגים בדרכים בין-עירוניות, (3) סה"כ הרוגים בדרכים עירוניות.

אורך כל סדרה היה 72 תצפיות חודשיות. בכל סדרה, כללנו כתקופה "לפני", דהיינו שלב ראשון של בניית התרשים, את 60 החודשים הראשונים בסדרה. התקופה "אחרי" אליה התייחסנו כשלב שני כללה את החודשים 61-72.

סדרה ראשונה היא סכום של שתי האחרות.

כמו כן, נתחנו סדרות מלאכותיות, מהסיבה הבאה: בבחינת ביצועי תרשימי הבקרה על סדרות הנתונים, כאשר תרשים מצביע על שינוי בתהליך, אין אנו יכולים לדעת האם אכן היה שינוי. מצד שני, אם התרשימים לא מגלים שינוי, איננו יכולים לדעת האם אכן לא חל שינוי בתהליך. על מנת לבדוק את ביצועי תרשימי הבקרה על סדרות הקרובות ככל האפשר לסדרות הנתונים המקוריות, יצרנו בעזרת סימולציה סדרות מלאכותיות. יצרנו הן סדרה המייצגת תהליך ללא שינוי והן סדרות עם שינוי (גם עם שינוי קטן וגם עם שינוי גדול יחסית).

עבור כל סדרה שבניתוח, שורטטו ארבעה תרשימי בקרה. שני התרשימים הראשונים הם תרשימי Shewhart. התרשים הראשון התקבל על-ידי פרוצדורת Shewhart של SAS/QC, והשני על-ידי פונקציית qcc של ספריית qcc מתוכנת R (Scrucca, 2004). שני התרשימים זהים, פרט לסימונים של "אירועים מיוחדים", לכן הצגנו את שניהם. פרט לגילוי נקודות החורגות מגבולות הבקרה, מצביע התרשים מתוכנת R על אירועים מיוחדים ("violating runs") שמזוהים על-פי הכלל של K נקודות או יותר ברצף מצדו האחד של קו האמצע (ממוצע התהליך). ברירת המחדל, אותה השארנו, היא  $K=7$ . אין בתרשים מסוג זה התייחסות למקרה של רצף של נקודות שעולות או יורדות מונוטונית, או כללים אחרים של "אירועים מיוחדים". התרשים השלישי עבור כל סדרה הינו תרשים מסוג CUSUM והרביעי מסוג EWMA. שני התרשימים האחרונים בוצעו גם הם באמצעות פונקציות cusum ו-ewma, בהתאמה, של ספריית qcc מתוכנת R (Scrucca, 2004).

בניתוח הסדרות המקוריות נמצא שעבור הסדרה הראשונה של סה"כ הרוגים כל התרשימים הראו שהתהליך בבקרה. לעומת זאת, עבור הסדרה של הרוגים בדרכים הבין-עירוניות בבחינת ארבעת סוגי התרשימים לא היו מסקנות שוות. לפי תרשימי Shewhart של SAS/QC נראה היה שבתקופה "אחרי" יתכן שהיה שינוי, מאחר והיה רצף של נקודות מעל לממוצע הצפוי. אולם שאר התרשימים לא הראו כל סטייה מבקרה. עבור הסדרה של הרוגים בדרכים העירוניות כל ארבעת סוגי התרשימים הראו שהתהליך לא היה בבקרה מלאה, גם לא בתקופה "לפני" וגם לא בתקופה "אחרי".

השוואה בין הממצאים בכל 4 התרשימים מדגימה את הרגישות השונה שבכל סוג ובהתאם לכך את המסקנות שניתן לקבל מכל תרשים. לעתים, כמצופה, אין המסקנות זהות. לתרשים מהסוג Shewhart המופק ב-SAS יש יתרון בקלות הסקת המסקנות ממנו בגלל ציון אופי הסטייה. לא נראה שיש יתרון בתרשים מהסוג EWMA כאשר בוחנים אותו בתוספת לשאר התרשימים. לעומת זאת, ראינו יתרון בתוספת של תרשים מסוג CUSUM אשר עזר בגילוי שינוי מצטבר בתהליך המבוקר. לכן, מומלץ להשתמש הן בתרשים Shewhart והן בתרשים CUSUM.

הסדרות המלאכותיות שיצרנו הדגימו שגם כאשר הנתונים מייצגים תהליך בבקרה, התרשימים עלולים להצביע על אפשרות שהתהליך אינו יציב ("false alarm"). עם זאת, ראינו שגם שינוי קטן יחסית נתגלה בתרשימים.

נבדקו גם היתרונות שבתרשימי בקרה רב-ממדיים. לא מצאנו יתרון בשיטה זו מעבר לשימוש בתרשימים שבהם כל סדרה נבדקת לחוד. לצורך מעקב על נפגעי תאונות דרכים יש משמעות ועניין רב בבחינה נפרדת של כל סדרה.

בנושא זה קיים שוני בין העניין שיש בשימוש בתרשימי הבקרה עבור נפגעי תאונות דרכים לבין מעקב על ייצור בתעשייה הכוללת עשרות או מאות רכיבים. בתעשייה, מאחר ואין זה מעשי לבחון מאות תרשימים, יש יתרון בבקרת ייצור של הרבה פריטים בתרשימים הרב-ממדי ככלי שימושי של Screening. במידה ומתגלה בעייה, אזי בשלב שני מחפשים את מקורה.

### **סיכום חלק שני**

בסיכום, יש יתרון רב בשימוש בתרשימי הבקרה **על בסיס השאריות** ככלי מעקב על הנפגעים בתאונות הדרכים. הראינו את היתרון בבחינה סימולטנית של שני סוגי התרשימים, מסוג Shewhart ו-CUSUM.

בתרשים מסוג Shewhart גבולות הבקרה אופקיים, לכן קל למשתמש לתפוס היכן מתחולל שינוי, ומהותו - עליה, ירידה או חריגה חד פעמית, לעומת הצפוי. גילוי זה מתאפשר מאחר שהערכים המוצגים בתרשים שהם שאריות, הם מנוכי מגמה ועונתיות, ומנורמלים.

בשני סוגי התרשימים: Shewhart ו-CUSUM - לאחר שלב ראשון של חישוב הפרמטרים הנדרשים לבניית תרשימי הבקרה על-פי התקופה "לפני", קל לחשב את הערכים המבוקרים על-ידי התרשים בתקופה "אחרי", וקל לשרטט את תרשימי הבקרה. מה שנדרש הוא רק חישובים אלמנטריים שניתנים לביצוע אף בעזרת מחשבון, ואפשרות לשרטוט גרפים פשוטים. עובדה זאת מאפשרת לשלב את התרשימים במערכת מידע, ואפילו לשרטט אותם ידנית. לכך יש יתרון מעשי.

החיסרון בשיטה שבה בוחנים שאריות הוא שלערכים המופיעים בתרשים אין למעשה מובן, מאחר והם לא מבטאים בערכים של מספר נפגעים, אלא במונחים של שאריות.

שיטות חדשניות, בספרייה surveillance אשר בחבילת R מאפשרות לבנות תרשימי בקרה, על בסיס הערכים הצפויים על-פי המודל, וגבולות בקרה במונחים של מספרי נפגעים. בכך מתאפשר מעקב אחרי הערכים הממשיים של הסדרות המבוקרות. שיטות אלה פותחו לאחרונה עבור נתונים מהתפלגות פואסונית וגם בינומית שלילית, ואלה ההתפלגויות המתאימות לנתוני נפגעים בתאונות. אולם גבולות הבקרה אינם קווים אופקיים, המקשים על המעקב. כמו כן, קשה להסיק אם החריגה מגבולות הבקרה

היא גדולה או קטנה באופן משמעותי ביחס לצפוי, בהתחשב בשונות הצפויה באותה נקודת זמן. יתר על כן, החישובים מורכבים בהרבה לעומת השיטות שהצענו במחקר הנוכחי.

עם זאת, רצוי היה להמשיך במחקר כדי להשוות ביתר עומק את השיטות החדשניות הללו לעומת השיטות המופיעות במסמך זה. בפרט, האם יש לאמץ אותן ככלי בקרה בנוסף לתרשימים שהמלצנו, דהיינו התרשימים מסוג Shewhart ו-CUSUM על בסיס השאריות.

# הדו"ח המפורט

## הסבר על הדו"ח המפורט

בחלק הראשון של הדו"ח המפורט מובא חקר הספרות על השיטות החדשניות שפותחו לניתוח נתוני מנייה, וליישומן של שיטות אלה לניתוח 13 סדרות של נתונים שונים על הרוגים מתאונות דרכים בשנים 2003-2008.

בחקר הספרות מצאנו במגוון שטחים יישומים שבהם יושמו השיטות השונות. חלקם בתחום של ניתוח נתוני תאונות, ובפרט תאונות דרכים שהוא התחום בעל העניין במחקר זה. דוגמאות בתחומים אחרים היו: בקרימינולוגיה (לדוגמה: האם שינוי בחוקי ענישה מביא לירידה במספר מקרי פשע); בתיירות (לדוגמה: האם השקעה באתר תיירות הביאה לגידול במספר התיירים באתר); בבריאות וסביבה (לדוגמה: האם יש קשר בין רמת זיהום אויר ומספר פניות לחדרי מיון עקב בעיות נשימה) בדמוגרפיה (לדוגמה: האם חל שינוי באוכלוסיות מסוימות במספר הילדים במשפחה; בשיווק (לדוגמה: שינוי בצריכת מוצר על ידי צרכנים לאורך זמן ואפקט פרסום על התנהגות הצרכנים).

בדו"ח מוצגות השיטות שבחרנו לניתוח נתוני תאונות הדרכים. בין השיקולים שהביאו לבחירת שיטות אלה הייתה התאמה לאופי סדרות אלה. שיקול לוגיסטי חשוב נוסף בבחירת שיטות הניתוח היה זמינות תוכנה מתאימה ופשטות יחסית של השימוש בה. מצאנו שפרוצדורה Glimmix של חבילת התכנה SAS נתנת מענה הולם לשאלות שלמטרתן בוצע הניתוח.

בניתוח הסטטיסטי שבו יושמה השיטות בוצעה השוואה בין תקופה "אחרונה", לעומת תקופה קודמת, הכוללת מספר שנים, או שנה. מטרת הניתוח הייתה לבדוק:

- האם מגמת הבטיחות (safety) עבור הרוגים/נפגעים בתקופה אחרונה השתנתה באופן מובהק לעומת המגמה בתקופה הקודמת?

- האם הבטיחות עבור הרוגים/נפגעים בתקופה אחרונה שונה באופן מובהק מהבטיחות בתקופה הקודמת?

אילו שתי שאלות שונות שכן הרמה יכולה להשתנות אך לא קצב השינוי.

נדגיש שבמושג "בטיחות" אנו מתכוונים לתוחלת מספר האירועים היומי. לכן, "בטיחות" עבור הרוגים/נפגעים הינה תוחלת מספר הרוגים/נפגעים היומי.

החלק השני בדו"ח המפורט דן בשיטות של תרשימי בקרה ושילובם בניתוח סדרות זמן של מנייה כאמצעי מעקב על ההשתנות בזמן של סדרות מסוג זה. השיטות יושמו על 3 סדרות נתונים של הרוגים בתאונות דרכים. הדוח כולל פירוט של השיטות, הדגמת יישומן על הסדרות וכן את מסקנות הניתוח שבו יושמו השיטות על סדרות אילו.

עבודת מחקר זו הייתה בהיקף מאד רחב. עיון בכל הממצאים עלול להיות בלתי מעשי ומיותר. לפיכך, בחרנו שלא לפרט כמו שפרטנו בדוח הביניים אשר סיכם ממצאי חלק ראשון בלבד. יוצגו ממצאים שנראו לנו מעניינים ומספיקים לקורא. המעוניינים יוכלו לקבל מאתנו, את כל פלטי הניתוחים לכל סדרה.

## הקדמה

הסדרות של נתוני תאונות דרכים בהן נעסוק במחקר זה הינן סדרות עיתיות (time series) של נתונים שלמים אי-שליליים ובדרך כלל בסדרי גודל קטנים, (תלוי במידת האגרטיביות של הסדרה). נתונים מסוג זה, הנקראים נתוני מניה (count data) מופיעים בשלושים השנים האחרונות במגוון רחב של תחומים, ולכן נוצר צורך בפיתוח שיטות לניתוח סדרות כאלו.

אחד היישומים הראשונים לניתוח סדרות של נתוני מניה הוצג כבר ב 1898 על ידי Bortkiewicz אשר הראה כי תהליך פואסון מתאים לתיאור נתוני מספר המתים מבעיטות פרדות בצבא הפרוסי, בשנים 1875-1894. במחקרים הבאים ניתחו כמובן מספרי אבידות כתוצאה מסיבות מוות אחרות. חלק גדול מהיישומים של ניתוח סדרות מנייה כולל ניתוח ממצאי תאונות דרכים. חלק אחר משמעותי כולל ניתוח נתונים כלכליים, ובפרט פיננסיים. בספרות של שיטות ניתוח בכלכלה ניתן למצוא מספר רב של מאמרים בנושא זה. בין החוקרים הבולטים בתחום מחקר זה הוא Winkelmann שספרו *Econometric Analysis of Count Data* יצא כבר בחמש מהדורות, (האחרונה ב-2008).

מגוון גישות הוצעו למידול הנתונים ולהסקה, אולם אף אחת מהן לא התקבלה כשיטה הדומיננטית, (Jung & Tremayne, 2010).

על פי Jung & Tremayne (2010) הסקירה הראשונה של הגישות השונות למידול נתוני מנייה הינה של MacDonald and Zucchini (1997). ספר הלימוד הראשון העוסק במודלים של סדרות עיתיות של נתוני מנייה הינו Cameron and Trivedi (1998). טענתם שהוצגה בספרם ב-1998, שאין מודל אחד דומיננטי לטיפול בנתונים כאלה נכונה עד ימינו.

החלק הראשון של דוח זה עוסק בסקירה של שיטות ניתוח של מודלים עבור סדרות עיתיות של נתוני מנייה, וסיווגם. חלק מהשיטות יושמו לניתוח נתוני הסדרות של תאונות הדרכים. בהקשר זה כדאי להזכיר את אחת מאמרותיו של הסטטיטיקאי המפורסם George Box המצוטטת לעתים קרובות וגם Jung & Tremayne (2010) מצטטים אותה במאמרים:

*Essentially, all models are wrong, but some are useful*

אכן, אנו מצאנו את המודלים שהתאמנו שימושיים להסקת מסקנות מעשיות.

## חלק ראשון - בחינת שינוי במגמה ובקצב התאונות

### 1. ניתוח סדרות עיתיות של נתוני מנייה

#### 1.1. כללי

סדרות עיתיות של נתוני מנייה נוצרות או על ידי תהליך פואסוני, או תהליך ממשפחה רחבה יותר שיש בה גם פרמטר של over-dispersion, או על-ידי תהליך בינומי שלילי. יש למעשה שתי צורות שבה משתמשים בהתפלגות הבינומית השלילית. באחת, מביעים את הקשר בין השונות והתוחלת כקשר ליניארי (NB1), ובשנייה כקשר ריבועי (NB2). במרבית המקרים נמצא שהצורה של (NB2) היא היותר מתאימה. לעתים, ניתן להניח שמספרי האירועים בקטעי זמן עוקבים הם בלתי תלויים. הנחה זו סבירה כאשר בוחנים את התהליך מותנה באוסף מתאים של משתנים מסבירים ומשתנים אלה מספיקים להסביר את מבנה התלות בנתונים. במקרים אלה ניתן להתייחס לתהליך (המותנה) כחסר זיכרון, Cameron & Trivedi, 1998).

מסיבה זו, ניתוח נתוני מנייה נעשה בכמה שלבים, כאשר בשלב הראשון בודקים אם עבור התהליך המותנה באוסף מסבירים הנחת אי התלות מתאימה. בשלב ראשון זה מתאימים מודל רגרסיה, (כמו רגרסיה פואסונית או הרחבות שלה עבור נתונים עם over-dispersion, או רגרסיה בינומית שלילית). התאמה זו נעשית תוך התעלמות מתלות אפשרית בין הנתונים. לאחר התאמת הרגרסיה בוחנים האם אין מתאם סדרתי בין השאריות. המבחנים מותאמים לסוג השאריות בו משתמשים.

עבור מודלים של נתוני מנייה אין סוג אחד של שאריות שהינו בעל תוחלת אפס, שונות קבועה (הומוסקדסטיות) והתפלגות סימטרית. לכן מקובל לחשב מספר סוגים של שאריות על פי התכונה שרוצים שהשאריות תקיימנה. נמנה כמה מסוגים אלה.

נסמן ב-  $Y_t$  את התצפית ה-  $t$ -ית של הסדרה וב-  $x_t$  את וקטור המסבירים עבור התצפית ה-  $t$ -ית.

$\mu_t$  היא התוחלת המותנית של  $Y_t$  בהינתן  $\beta$ .  $x_t$  הוא וקטור הפרמטרים הבלתי ידועים. אם לפי הנחת המודל  $\mu_t = \exp(x_t^T \beta)$ , אזי:  $\hat{\mu}_t = \exp(x_t^T \hat{\beta})$ .

השארית הטבעית ביותר לחישוב הינה השארית הגולמית (raw residual). היא מוגדרת באופן הבא:

$$r_t = Y_t - \hat{\mu}_t$$

היתרון בשאריות הגולמיות הוא פשטותן. חסרון הוא הטרנסכדסטיות שלהן, (אינן בעלות שונות שווה). במבחנים המתאימים מתחשבים בכך שהשאריות הללו הינן הטרנסכדסטיות.

הסוג השני של השאריות הינו שאריות פירסון (Pearson residual). שאריות פירסון מוגדרת באופן הבא:

$$p_t = \frac{Y_t - \hat{\mu}_t}{\sqrt{\hat{w}_t}}$$



עבור מודל פואסוני, פואסוני עם dispersion ו-NB2 הערך במכנה  $w$  מוגדר בתור  $w = \mu$ , או  $w = \alpha\mu$ , או-  $w = \mu + \alpha\mu^2$  בהתאמה. במדגמים גדולים יש לשאריות אלה ממוצע אפס ושונות קבועה השווה לאחד. אבל התפלגותן אינה סימטרית.

הסוג השלישי של השאריות הינו שאריות דיוויאנס (deviance residual). שארית זו מוגדרת באופן הבא (עבור משפחה אקספוננציאלית לינארית):

$$d_t = \text{sign}(Y_t - \hat{\mu}_t) \sqrt{2 \{ \ell(Y_t) - \ell(\hat{\mu}_t) \}}$$

הוא לוג-הצפיפות של  $Y_t$ , המחושב ב-  
 $\mu = \hat{\mu}_t$  ו-  $\ell(Y_t)$  הוא לוג הצפיפות המחושבת ב-  $\mu = Y_t$

עבור ההתפלגות הפואסונית, שארית הדיוויאנס שווה ל:

$$d_t = \text{sign}(Y_t - \hat{\mu}_t) \sqrt{2 \left\{ Y_t \log \left( \frac{Y_t}{\hat{\mu}_t} \right) - (Y_t - \hat{\mu}_t) \right\}}$$

ועבור ההתפלגות הבינומית שלילית שארית שווה ל:

$$d_t = \text{sign}(Y_t - \hat{\mu}_t) \sqrt{\max \left( 0, 2 \left\{ Y_t \log \left( \frac{Y_t}{\hat{\mu}_t} \right) - (Y_t + \alpha^{-1}) \log \left( \frac{Y_t + \alpha^{-1}}{\hat{\mu}_t + \alpha^{-1}} \right) \right\} \right)}$$

המניע להגדרת שאריות אלו הוא שעבור ההתפלגות הנורמאלית הן שוות למעשה לשאריות המתוקננות.

הסוג הרביעי של השאריות הינו שאריות Anscombe. להגדרת שארית זו מבצעים התמרה של  $Y_t$  כך של תוצאה המותמרת תהיה התפלגות קרובה ביותר להתפלגות הנורמאלית. לערך המותמר מבצעים סטנדרטיזציה, כך שתוחלתו תהיה אפס ושונותו שווה לאחד.

עבור ההתפלגות הפואסונית, שארית זו שווה ל:

$$a_t = \frac{1.5 \left( Y_t^{2/3} - \hat{\mu}_t^{2/3} \right)}{\hat{\mu}_t^{1/6}}$$

בדיקת השאריות עלולה שלא לגלות תלות עבור מבני תלות מסוימים. דוגמה לכך מוצגת במאמרם של Davis et al (2000). הם הראו שכאשר ישנו תהליך חבוי (latent process) הגורם לתלות בין התצפיות, אזי חוסר מתאם סדרתי, או מתאם סדרתי נמוך מאוד בתהליך המקורי יכול להסתיר מתאם סדרתי אפילו גדול בתהליך החבוי. המתאם הסדרתי אותו רואים בתהליך המקורי מהווה רק חסם תחתון למתאם הסדרתי בתהליך החבוי וההבדל בערכי המתאמים הסדרתיים האלה עלול להיות גדול.

עבור מודלים של רגרסיה מסוג Generalized Linear Models ו/או Generalized Additive Models, קיימות בספרות ובתוכנות סטטיסטיות (R, SAS) אפשרויות ניתוח ודיאגנוסטיקה רבות. לכן, סביר לנצל בשלב הראשוני של הרצת רגרסיה תוך התעלמות מתלות אפשרית בין הנתונים. ממצאי שלב זה ניתן ללמוד האם כדאי לבצע טרנספורמציות למשתנים המסבירים, האם במודל היו משתנים חסרים (כמו תיאור מגמה). על-ידי שימוש בשאריות ניתן גם ללמוד על מבנה התלות הסדרתית. כאמור, יכולים להיות מבני תלות שלא בהכרח ניתנים לגילוי על ידי ניתוח כזה, ובהמשך נדון בדרך להתמודד עם בעיה זו.

## 1.2. סיווג מודלים לסדרות עיתיות של נתוני מנייה

בסעיף זה נסקור מספר סיווגים אפשריים של המודלים לסדרות עיתיות של נתוני מנייה. ישנן מספר דרכים לסיווג לקבוצות, אולם כפי שמציינים Cameron & Trivedi (1998) אין סיווג פשוט המכיל את כל המודלים.

### 1.2.1. מודלים מונעי תצפיות (observation driven) לעומת מודלים מונעי פרמטרים (parameter driven)

Cox (1981) אפיין שני סוגים של מודלים של סדרות עיתיות: observation driven ו-parameter driven. במקרה של observation driven model, ההתפלגות המותנית של  $Y_t$  נתונה על ידי פונקציה של מומנטים או צפיפויות, או פונקציה מפורשת של תצפיות העבר. בשיטות שונות מוודאים שהמודל מתאים לתאר נתוני מנייה. (לדוגמה, בשיטה שתוסבר בהמשך של "סינון בינומי" בה משתמשים במודלים של Al-Osh & Alzaid, 1987; McKenzie, INAR - Integer Valued Autoregressive models - ראה, 1988).

דוגמה למודל של observation driven mode מובאת במאמר של Davis et al (2001). המודל הוא:

$$E(Y_t / \mu_t) = \mu_t$$

$$\log(\mu_t) = x_t^T \beta + v_t$$

$$Y_t | \mu_t \sim \text{Poisson}(\mu_t)$$

כאשר  $v_t$  הוא תהליך שניתן לתיאור כפונקציה של תצפיות העבר  $s < t$ .  $Y_s$ . לדוגמה:

$$v_t = \gamma_1 Y_{t-1} + \dots + \gamma_p Y_{t-p}$$

היתרון של מודל כזה מבחינת המשתמש הוא בפשטות יצירת תחזיות. החיסרון העיקרי הוא בקושי לפרש את פרמטרי המודל ואת הערך  $x_t^T \beta$ . במודל זה מקבלים:

$$E(Y_t) = \exp(x_t^T \beta) E\{\exp(v_1 Y_{t-1} + \dots + v_p Y_{t-p})\}$$

ולכן קשה לפרש את משמעות הביטוי  $x_t^T \beta$ .

מודלים מהסוג של מונעי תצפיות הם המודלים הנקראים גם Generalized Linear ARMA (GLARMA models) - ראה (Davis et al 1999).

במודלים (GLARMA (p,q):

$$Y_t | (Y_1, \dots, Y_{t-1}) \sim \text{Poisson}(\mu_t)$$

$$\log(\mu_t) = x_t^T \phi + z_t$$

$$z_t = \sum_{j=1}^p \alpha_j (z_{t-j} + e_{t-j}) + \sum_{j=1}^q \beta_j e_{t-j}$$

$$\text{with } e_t = \frac{Y_t - \mu_t}{\mu_t^{0.5}}$$

$$e_t = z_t = 0 \quad \text{for } t \leq 0$$

במקרה של parameter driven model התלות מושרית על-ידי תהליך נסתר (latent process). כלומר, המתאם בין התצפיות מתבטא במודל על ידי הצגת ההתפלגות המותנית של נתוני המנייה כפונקציה של תהליך חבוי סטוכסטי עם תלות. בגישה זו מתייחסים למודלים למעשה כסוג של STATE-SPACE MODELS.

במאמרם, Davis et al (1999) נותנים סקירה מקיפה על מודלים שהם מונעי פרמטרים. דוגמה למודל כזה (מתוך (Davis et al, 2001) הוא המודל הבא:

$$Y_t | \mu_t \sim \text{Poisson}(\mu_t)$$

$$E(Y_t / \mu_t) = \mu_t$$

$$\log(\mu_t) = x_t^T \beta + v_t$$

כאשר  $\{v_t\}$  הינו תהליך סטציונרי גאוס. תהליך כזה יכול להיות למשל אוטו-רגרסיה מסדר ראשון, AR(1). במקרה זה,

$$(v_t + \frac{\sigma^2}{2}) = \phi(v_{t-1} + \frac{\sigma^2}{2}) + \varepsilon_t$$

$$\{\varepsilon_t\} \sim \text{IID}(N(0, \sigma^2(1-\phi^2)))$$

יתרונם של מודל של parameter driven model הוא יכולת הפירוש (interpretability) של מקדמי הרגרסיה  $\beta$ , מכיוון שבמקרה זה:

$$E(Y_t) = \exp(x_t^T \beta) E \exp(v_t) = \exp(x_t^T \beta)$$

$$E \exp(v_t) = 1 \quad \text{כאשר}$$

או ניתן גם לבטאו על ידי:

$$E(Y_t) = \exp(x_t^T \beta) E \exp(v_t) = \exp\left\{x_t^T \beta + \frac{\sigma_v^2}{2}\right\}$$

$$\text{Var}(v_t) = \sigma_v^2 \quad \text{כאשר}$$

חסרונות של מודל כזה הם שהאמידה אינה תהליך פשוט. אולם, תוכנות מתאימות המנצלות את כוח המחשוב הזמין פותרות בעיה זו. חיזוי גם הוא אינו פשוט, על בסיס המודל.

שימוש במודל parameter driven models הודגם על-ידי (Davis et al (2001) עבור נתונים יומיים של מספר הפונים עקב בעיות אסטמה לבית חולים בסידיני אוסטרליה. המודל אותו התאימו היה:

$$v_t = \left(\frac{1}{\Phi(B)} - 1\right) \varepsilon_t$$

$$\Phi(B) = 1 - \varphi_1 B - \varphi_3 B^3 - \varphi_7 B^7 - \varphi_{10} B^{10}$$

במאמרם של (Davis & Wu (2009) מוצג בפירוט מודל זה עם חקירה מעמיקה על תכונותיו והדגמה על שימוש.

אנו השתמשנו לניתוח נתוני תאונות הדרכים גם (ולא רק) במודלים מהסוג parameter driven model.

### **1.2.2. מודלים מותנים (conditional) לעומת שוליים (marginal)**

גישה שונה לסיווג מודלים היא הבחנה בין מודלים שוליים (marginal) לבין מודלים מותנים (conditional). סיווג זה נפוץ בספרות הסטטיסטית של Generalized Linear Models (GZLM).

מודלים מותנים מבחינה מושגית, אקוויולנטים למודלים מונעי תצפיות (observation driven). מודלים אלה עוסקים בהתפלגויות מותנות (ולכן גם במומנטים) של נתוני מנייה, בהינתן תצפיות עבר של המשתנה התלוי  $Y_t$  ובערכי המסבירים  $x_t$ . לעומת זאת, במודלים שוליים ממדלים התפלגויות שוליות וקשרים (מתאמים או קווריאנסים) בין ערכי  $Y_t$  שונים, ובנפרד ממדלים את הקשרים בין  $Y_t$  לבין המשתנים המסבירים  $x_t$ .

בפרוצדורת GLIMMIX של SAS, אשר תשמש בחישובינו בחלק הראשון של המחקר יש הבחנה בין שני סוגי מודלים אלה. במודלים המותאמים על ידי פרודורת GLIMMIX שהם מסוג Generalized Linear Mixed Models יש שתי צורות אפשריות לבטא את המתאמים בין התצפיות. או על ידי השריית מתאם דרך המשתנים המסבירים, בהוספת מרכיב אקראי, ו/או על ידי מידול מתאמים בין הנתונים באופן ישיר. בפרוצדורת GLIMMIX שתי האפשרויות נקראות "G-side" ו-"R-side" בהתאמה, (Schabenberger, 2005). בשיטה המתאימה ל-"G-side" מוסיפים כאמור אפקטים אקראיים ל-

predictor. משוואת המודל היא:  $g(E(Y|\gamma)) = x^T\beta + z^T\gamma$ , כאשר  $g$  הינה פונקצית הקשר בין תוחלת  $Y$  (המותנית) לבין פונקציה ליניארית של המסבירים, האפקטים האקראיים בין המסבירים הם האלמנטים של  $\gamma$ , אשר לפי ההנחה הוא וקטור של משתנים מקריים נורמאליים עם תוחלת אפס ומטריצת שונות  $G$ . כלומר, במקום לבטא את ההתפלגות של  $Y$ , כמו במקרה של Generalized Linear Models, מבטאים במודל כזה את ההתפלגות המותנית של  $Y|\gamma$ , שהיא התגובה (response) המותנית של  $Y$  במרכיב האקראי. לכן, ניסוח זה של המודל ידוע כ**מודל מותנה**.

דוגמה למודל כזה היא דוגמת מודל ה- observation driven ממאמרם של (Davis et al (2001) המופיעה בסעיף הקודם.

דוגמה נוספת היא המודל הבינומי שלילי שתואר בפירוט על ידי (Davis & Wu (2009). האמידה על בסיס מודל זה בוצעה במאמרם בעזרת הפרוצדורה GLIMMIX של SAS.

$$Y_t / \alpha_t \sim \text{NegBin}(r, p_t)$$

$$r > 0$$

$$-\log \frac{p_t}{1-p_t} = x^T\beta + \alpha_t$$

$$P(Y_t = y_t / \alpha_t) = \binom{y_t + r - 1}{r - 1} p_t^r (1-p_t)^{y_t}$$

$\beta$  הוא וקטור הפרמטרים שיש לאמוד.

על פי המודל

$$E(Y_t / \alpha_t) = \frac{r(1-p_t)}{p_t} = r \exp(x^T\beta + \alpha_t)$$

ההנחה הנוספת במאמר הייתה שהתהליך החבוי הוא סטציונרי במובן החזק, (strictly stationary). בסימולציות המובאות במאמר הודגם טיב המודל עבור תהליך חבוי מסוג AR(1), דהיינו תהליך:

$$\alpha_t = \varphi\alpha_{t-1} + z_t$$

לעומת מודלים מהסוג של "G-side", מודל עם "R-side" בלבד ידוע כ**מודל שולי** מכיוון שאין אפקטים אקראיים שבהם מתנים את התגובה  $Y$ . במודל שולי מוצגת התגובה (response) על-ידי:  $g(E(Y_t)) = x_t^T\beta$ . בהגדרות המודל יש גם לציין מהי ההתפלגות השולית של  $Y$  (בהינתן המסבירים), למשל: לוגיסטית, או פואסונית, או בינומית שלילית. בנוסף, יש לציין מה מטריצת השונות של הווקטור  $\underline{Y}$ . נהוג לסמן ב- $A$  מטריצה אלכסונית שהאבר ה- $i$  שלה מבטא את השונות של התצפית ה- $i$  ת, שהיא פונקציה של התוחלת של הרכיב ה- $i$  של  $\underline{Y}$ . (קיים קשר פונקציונאלי בין התוחלת והשונות קשורות במודלים מהמשפחה האקספוננציאלית. פונקציה זו עבור  $Y$  עם תוחלת  $\mu$  שווה ל  $\mu$  עבור  $Y$  המפולג

פואסונית ושווה ל-  $\mu + k\mu^2$ , עבור  $Y$  המפולג בינומית שלילית). מטריצת השונות של התגובה במודל מהסוג "R-side" בלבד נתונה על-ידי הביטוי:  $\text{Var}(\underline{Y}) = A^{1/2} R A^{1/2}$ , כאשר  $R$  מבטאת את מבנה הקובריאנס של התגובה. למשל, אוטורגרסיה מסדר ראשון-AR(1). בעבודה זאת נשתמש בשני מבני  $AR(1)$  ו-SP(EXP), או מודל דומה - SP(POW). אם נסמן ב- $i$  ו- $j$  שני זמנים, אזי: בתהליך מהסוג  $AR(1)$ , אברי המטריצה  $R$  הם:  $r(i, j) = \sigma^2 \rho^{|i-j|}$  ועבור SP(EXP) אברי המטריצה  $R$  הם:  $r(i, j) = \sigma^2 \exp\{-|i-j|/\alpha\}$ , כאשר  $\alpha$  קבוע חיובי. SP(POW) מציין מודל בו:  $r(i, j) = \sigma^2 \rho^{|i-j|}$ , כאשר  $\rho$  קבוע חיובי.

### 1.2.3.1. מודלים נוספים לסדרות עיתיות של נתוני מנייה

קיימים מודלים נוספים שימושיים אשר לא ניתן לשייכם לפי הסיווגים הקודמים לאחת בלבד מהקטגוריות הנ"ל. נציין שני סוגי מודלים כאלה.

#### 1.2.3.1. תהליך INAR

תהליך INAR הוא תהליך Integer Autoregressive של משתנה מנייה. במודל כזה  $Y_t$  מובע כסכום של ערכי עבר ומשתנה בלתי תלוי. לכן, ניתן לבטא במודל כזה את ההתפלגות השולית של  $Y_t$ . נתאר בפירוט תהליך INAR (1) עבור ההתפלגות הפואסונית, (INAR(1)-poisson).

$Y_t$  הוא תהליך INAR(1) להתפלגות פואסונית אם:

$$Y_t = \alpha \circ Y_{t-1} + \varepsilon_t, \text{ כאשר } \alpha \text{ מציין "מתפלג כמו"}$$

$$Y_{t-1} \sim \text{Poisson}(\lambda)$$

$$\varepsilon_t \sim \text{Poisson}[(1-\alpha)\lambda]$$

$$Y_{t-1}, \varepsilon_t \text{ independent}$$

$$0 \leq \alpha \leq 1$$

$$\alpha \circ Y_{t-1} = \sum_{i=1}^{Y_{t-1}} d_i$$

$d_i$  הם משתנים בלתי תלויים בינאריים המקיימים:

$$P(d_i = 1) = 1 - P(d_i = 0) = \alpha$$

הסימון  $\alpha \circ Y_{t-1}$  מציין שזה עירוב של התפלגות בינומית ופואסונית.  $d_i$ ,  $Y_{t-1}$  הם בלתי תלויים. הסימון "o" נקרא על ידי McKenzie (1988): "דילול בינומי" (Binomial thinning).

מתאר את מספר המקרים מתוך (t-1) שנותרו בזמן t, כאשר הסתברות השרידות היא  $\alpha$ . ניתן להוכיח שאז:  $\alpha \circ Y_{t-1} \sim \text{Poisson}(\alpha\lambda)$ .

משמעות המודל ניתנת להסבר באופן הבא: התהליך  $\varepsilon_t$  מתאר את מספר המקרים החדשים שנכנסים לתהליך. מספר הכולל של מקרים בזמן t הוא סכום אלה ששרדו ועוד המקרים החדשים שנכנסו. ניתן להראות ש:

$$E(Y_t / Y_{t-1}) = \alpha Y_{t-1} + (1-\alpha)\lambda$$

ההתפלגות השולית המתקבלת היא  $Y_t \sim \text{Poisson}(\lambda)$  וניתן לבטאה על ידי השוויון  $Y_t = \sum_{j=0}^{\infty} \alpha^j \circ \varepsilon_{t-j}$ .

כלומר, האפקט של  $\varepsilon_t$  על  $Y_t$  דועך באופן אקספוננציאלי כאשר מגדילים את ה lag. אפשר להראות ש-  $\text{Cov}(Y_{t-j}, Y_t) = \alpha^j \text{Var}(Y_t)$  ומכאן שפונקציית המתאם הסדרתי היא  $\rho(\tau) = \alpha^\tau$ . תוצאה זו זהה למקרה של אוטו-רגרסיה מסדר ראשון בתהליך גאומי, אלא שכאן  $\alpha$  מוגבל להיות אי שלילי (באינטרוול  $[0, 1]$ ). יש לשים לב שמודל INAR(1) שהוצג כאן לא כולל משתנים מסבירים.

Cameron & Trivedi (1998) סוקרים את מודל ה-  $\text{poisson INAR}(1)$  שהוצע על-ידי Brännäs (1995). במודל זה, משלבים במשוואה  $Y_t = \alpha \circ Y_{t-1} + \varepsilon_t$  משתנים מסבירים, הן דרך פרמטר הדילול  $\alpha$  והן דרך משתנה המנייה החבוי  $\varepsilon_t$ . מניחים שהמשתנה הנסתר  $\varepsilon_t$  הינו בעל התפלגות פואסונית עם תוחלת  $\lambda_t$  המקיימת:  $\log(\lambda_t) = x_t^T \beta$ . כדי להבטיח ש- $\alpha_t$  יהיה בין 0 ל-1 משתמשים בפונקציה

$$\alpha_t = \frac{1}{1 + \exp(-z_t^T \nu)}$$

הלוגיסטית: אם לוקחים  $z_t = 1$  מתקבל  $\alpha_t$  קבוע.

עבור מודל זה:

$$E(Y_t | x_t, z_t, Y_{t-1}) = \frac{1}{1 + \exp(-z_t^T \nu)} * Y_t + \exp(x_t^T \beta)$$

$$\text{Var}(Y_t | x_t, z_t, Y_{t-1}) = \frac{\exp(-z_t^T \nu)}{[1 + \exp(-z_t^T \nu)]^2} * Y_t + \exp(x_t^T \beta)$$

המודל הפואסוני הורחב גם לפילוג בינומי שלילי על ידי McKenzie (1986). במקרה זה ההתפלגות של  $\varepsilon_t$  היא בינומית שלילית.

תהליך שהוא פונקציה של ערכי עבר של  $Y_t$  יכול להיות מותנה. לדוגמה תהליך פואסוני או בינומי שלילי שתוחלתו היא פונקציה של ערכי עבר של  $Y_t$ . לכן, מביעים את ההתפלגות המותנית של  $Y_t$ . דוגמה למודל כזה ניתנה על ידי Cameron & Trivedi (1998) ובה מתפלג פואסונית עם תוחלת השווה ל-

כאשר  $Y_{t-1}^*$  הוא ערך  $Y_{t-1}$  שבמקרה הצורך "תוקן" כדי שערכו יהיה חיובי. יש מספר דרכים לתיקון כזה. למשל:  $Y_{t-1}^* = \max(0.5, Y_{t-1})$ , או  $\log(Y_{t-1}^*) = \log(Y_{t-1} + 0.5)$ .

### State-Space Models .1.2.3.2

במודלים כמו INAR את ההתפלגות המותנית של  $Y_t$  מביעים כפונקציה של ערכי עבר של  $Y_t$  וכן וקטור המסבירים  $x_t$ . לעומת זאת, במודלים של State-space שגם נקראים מודלים עם פרמטרים התלויים בזמן, מובעת התלות של  $Y_t$  בתהליך סטוכסטי של הפרמטרים. בשיטות באסיאניות נהוג להשתמש לניתוח מודלים כאלה (West & Harrison, 1997).

במאמר Snyder et al (2007), הם השוו שני מודלים לתיאור סדרות זמן של נתוני מנייה, כאשר לשניהם מתייחסים כמודלים שונים מהסוג של State-Space. המודל האחד מונע תצפיות שלו הם קראו SSOE, כי הוא נחשב בתור Single Source of Error והשני, מונע פרמטרים כי הוא נחשב בתור Double Source of Error.

## 2. סקירת שלבי ניתוח סדרות ההרוגים בתאונות

מספר מודלים מתוך המודלים שנסקרו בסעיף הקודם יושמו במחקר זה לניתוח סדרות ההרוגים. הניתוחים המקדימים שבוצעו על הסדרות יוצגו בסעיף הבא. לאחר מכאן יוצגו הממצאים אשר התקבלו מניתוחים אלה.

### 2.1. שלב א: התאמת מודל מנייה ראשוני (עם התעלמות מתלות אפשרית) לסדרות המנותחות

שלב ראשוני בניתוח הסדרות החודשיות של נתוני ההרוגים היה התאמת מודל מנייה תוך התעלמות מתלות אפשרית. התאמה זו היא מקובלת כנקודת הפתיחה בהתאמת סדרות עיתיות לנתוני מנייה. על בסיס ניתוחים קודמים, ידוע שקיימת עונתיות וכן מגמה ליניארית בסדרות אלה. לפיכך, בדומה לשיטת הניתוח של סדרת נתוני מספר מקרי הפוליו החודשיים בארה"ב בשנים 1970-1983, (סדרה המשמשת לעיתים קרובות להדגמת שיטות לניתוח סדרות עיתיות של נתוני מנייה, למשל, Jung & Tremayne, 2010), כללנו כמשתנים מסבירים במודלים – מגמה ליניארית וזוגות של סינוסים וקוסינוסים בתדירויות שנתיות וחצי שנתיות. בנוסף, מכיוון שמספר הימים בכל חודש שונה, נכלל משתנה offset השווה ללוג מספר הימים בחודש (offset הינו משתנה מסביר שהמקדם שלו במודל נקבע להיות שווה ל-1).

כמו כן, התקופה שאליה מתייחסות סדרות הנתונים במחקר זה, כוללת את הזמן שבו התחוללה מלחמת לבנון השנייה. בגלל המלחמה, נגרם שינוי שאותו היה צורך לקחת בחשבון במודל. דבר זה נעשה על ידי יצירת משתנה אינדיקטור שכונה בשם WAR, המקבל את הערך 0, בחודשים שאינם חודשי מלחמה ו-1 בחודשי המלחמה (דהיינו, 7/2006 ו-8/2006). משתנה זה נכלל גם הוא כמשתנה מסביר במודל.

באחת הסדרות (אשר תצוין בהמשך) על בסיס ניתוח קודם (בהנחת אי תלות) כללנו בנוסף למשתנים אלה שבירת מגמה בתצפית ה-12.



משתנה נוסף שהוגדר במחקר זה לציון המלחמה בעזה היה WAR2. הוא הוגדר כשווה ל-0, עבור החודשים שלא היו חודשי המלחמה בעזה ושווה ל-1 עבור החודש שבו החלה המלחמה (דהיינו, 12/2008). משתנה זה נכלל במודל רק בנייתוח מהסוג "לפני"/"אחרי", ולא בשלב התאמת המודלים. היות ובחודש זה גם ארעה תאונה שבה היו 25 הרוגים בתאונת דרכים באוטובוס ליד אילת, הרי ש-WAR2 שימש למעשה הן לניטרול תאונה חריגה זו והן לניטרול השפעת המלחמה, אם הייתה כזאת.

המודל שהותאם עבור התקופה "לפני" היה עבור השנים 2003-2007. בנייתוח על כלל הנתונים נעשה שימוש בשני מודלים שונים – מודל אחד שבו יש רק שבירה של מגמה בתחילת 2008 ומודל שני בו יש אפשרות לקפיצה (שינוי חותך) ושבירה של מגמה בתחילת 2008.

תחילה בדקנו מהי ההתפלגות המתאימה לכל סדרה מבין מספר התפלגויות המתאימות לתיאור נתוני מנייה. הבחירה הייתה בין ההתפלגות הפואסונית, פואסונית עם dispersion (NB1), ובינומית שלילית (NB2). הרחבות אלה של המודל הפואסוני מבוססות על עבודתם של Cameron and Trivedi (1986). בדיקת טיב ההתאמה של כל אחד ממודלים בוצעה בשתי דרכים: האחת פורמאלית המשווה בין התפלגות פואסונית לבין NB1 ו NB2, ואילו השנייה גרפית.

הדרך הראשונה היא כאמור פורמאלית - על ידי מספר סטטיסטים מתאימים. ולהלן הפירוט של דרך זאת.

פונקצית ההסתברות של משתנה פואסוני נתונה על ידי

$$P(Y_i = y_i) = \frac{e^{-\mu_i} \mu_i^{y_i}}{y_i!} \quad y_i = 0, 1, 2, \dots$$

התוחלת היא  $E(Y_i) = \mu_i$  והשונות  $V(Y_i) = \mu_i$ .

פונקצית ההסתברות של משתנה בינומי שלילי NB2 נתונה על ידי:

$$P(Y_i = y_i) = \frac{\Gamma(y_i + \alpha^{-1})}{y_i! \Gamma(\alpha^{-1})} \left( \frac{\alpha^{-1}}{\alpha^{-1} + \mu_i} \right)^{\alpha^{-1}} \left( \frac{\mu_i}{\alpha^{-1} + \mu_i} \right)^{y_i} \quad y_i = 0, 1, 2, \dots$$

תוחלתה היא  $E(Y_i) = \mu_i$  והשונות  $V(Y_i) = \mu_i (1 + \alpha \mu_i)$ .

ההתפלגות הפואסונית הינה מקרה פרטי של ההתפלגות הבינומית שלילית, כאשר  $\alpha = 0$ . לכן, כדי לבחון את השערת ההתפלגות הפואסונית (כנגד השערת הבינומיות שלילית) ניתן לבצע בחינת ההשערה ש-  $\alpha = 0$ .

ההתפלגות השלישית הינה התפלגות NB1, אשר הינה למעשה התפלגות פואסונית עם DISPERSION. להתפלגות זו, אותה פונקצית הסתברות כמו למשתנה בינומי שלילי (NB2), פרט לכך שבכל מקום שמופיע  $\alpha^{-1}$ , הוא מוחלף ב-  $\alpha^{-1} \mu_i$ . לכן, תוחלת משתנה זה היא  $E(Y_i) = \mu_i$  ושונותו

$$V(Y_i) = \mu_i \left( 1 + \frac{1}{\alpha^{-1} \mu_i} \mu_i \right) = \mu_i (1 + \alpha)$$

ההתפלגות הפואסונית הינה מקרה פרטי של התפלגות זאת, כאשר  $\alpha = 0$ . לכן, כדי לבחון את השערת ההתפלגות הפואסונית (כנגד השערת התפלגות NB1), שוב ניתן לבצע את בחינת ההשערה ש-  $\alpha = 0$ . בשני מקרים אלה ההשערה האלטרנטיבית היא  $\alpha > 0$ .

מבחן WALS של השערה זו מדווח כמבחן t עבור האמד ל-  $\alpha$ , בפלט הפרוצדורה COUNTREG של SAS. לעיתים עקב בעיות בחישוב המודלים מסתיים חישוב  $\alpha$  ללא חישוב שגיאת התקן (SE) שלו, ולכן לא מחושב מבחן WALS במקרה זה. בנוסף, יש להתחשב בכך ה-Pvalue המובא לא מתייחס למגבלה ש-  $\alpha$  לא יכול לקבל ערכים שליליים. לכן הוא נכון רק כשהערך t גבוה מאוד ומתקבל Pvalue קטן מאוד.

הדרך השנייה לבחינת ההשערה, היא באמצעות מבחן יחס הנראות (Likelihood ratio test) לפי Cameron and Trivedi (1998). סטטיסטי המבחן הוא מינוס פעמיים (לוג הנראות עבור המודל הפואסוני פחות לוג הנראות עבור המודל הנבדק שהוא NB1 או NB2). אם נסמן את סטטיסטי המבחן ב-  $\hat{\lambda}$ . אזי ה-Pvalue מחושב כ:

$$Pvalue = \begin{cases} 1 & \hat{\lambda} = 0 \\ 0.5P(\chi_1^2 \geq \hat{\lambda}) & \hat{\lambda} > 0 \end{cases}$$

לעיתים, כאשר יש בעיות התכנסות באחד או שני המודלים המשווים יכול להתקבל  $\hat{\lambda}$  שלילי. במקרה זה יסומן הערך החסר של ה-PVALUE כ-1.

לבחירת ההתפלגות המתאימה למודלים נעשה גם שימוש בבחינה גרפית על ידי השוואת ההסתברויות הנצפות וההסתברויות הצפויות (Comparing the observed and predicted probabilities) עבור כל אחד מהמודלים הנבדקים. שיטה זאת הוצעה על ידי WenSui and Cela (2008) כאלטרנטיבה לשיטה הרווחת, על פיה טיב התאמת הרגרסיה מוערך על ידי השוואת הערך הצפוי (predicted) והנצפה (observed) של המשתנה התלוי. ביצוע חישוב זה נעשה בעזרת פרוצדורת COUNTREG של SAS/ETS גרסה 9.2, ובמאקרו PROBCOUNTS של SAS הניתן ב- <http://support.sas.com> (בגרסת SAS 9.22 ניתן להשלים חישוב זה ללא שימוש במאקרו PROBCOUNTS, משום שמקרו זה הוטמע לתוך פרוצדורת COUNTREG, אולם היא עדיין לא מופצת בטכניון בשעת כתיבת שורות אלה). בעזרת הפרוצדורה חושבו ממוצעי ההסתברויות הצפויות של נתוני המנייה (Average predicted count) (probability) מהרגרסיה הפואסונית, Over-dispersed poisson regression, והרגרסיה הבינומית שלילית, ובוצעה השוואה בין הסתברויות אלה להסתברויות שנצפו בפועל. לכל סדרה נבנה גרף המשווה בין ממוצע ההסתברויות הצפויות המתאימות לשלוש ההתפלגויות וההסתברויות הנצפות, כאשר בעזרת הצגה גרפית זו נבחר המודל המתאים.

## 2.2. בחינת תלות הנתונים

לאחר בחירת מודל ההתפלגות המתאימה לתיאור המודל לנתונים, כאשר הבחירה נעשתה ללא התחשבות בתלות הנתונים, חושבו השאריות מהמודל. חושבו מספר סוגי שאריות מבין הסוגים שהוצגו למעלה לבחינת התלות וצורתה (אם קיימת בנתונים). לשם כך נעשה שימוש בתרשימים ובמבחנים הבאים:

- The sample autocorrelation function plot (ACF)
- The sample inverse autocorrelation function plot (IACF)
- The sample partial autocorrelation function plot (PACF)

בתרשימים אלה מוצגים ערכי אמדי המתאמים הסדרתיים ורווחי הסמך המתאימים להם. בנוסף מובאת טבלת ממצאי מבחנים להשערה שהנתונים הינם נתוני רעש לבן, ולכן חסרי תלות. הסטטיסטים  $Q_m$  הם סטטיסטים שמשמשים בנוסחה של Ljung-Box לבחינה שקבוצת אמדי מתאמים סדרתיים של סדרה עיתית כוללת רק סטטיסטים מאוכלוסיה של מתאמים השווים כולם לאפס, לעומת האלטרנטיבה, שלפחות אחד מהמתאמים שונה מאפס.

הגדרת סטטיסטי המבחן עבור סידרה  $\{a_t\}$  היא

$$Q_m = n(n+2) \sum_{k=1}^m \frac{r_k^2}{(n-k)}$$

כאשר  $r_k$  הוא המתאם הסדרתי מסדר  $k$ :

$$r_k = \frac{\sum_{t=1}^{n-k} a_t a_{t+k}}{\sum_{t=1}^n a_t^2}$$

הסטטיסטי מושווה לערך מטבלת Chi-Square עם  $m$  דרגות חופש.

נוסחה זאת הוצעה על ידי Ljung & Box (1978) כתחליף לנוסחה של Box-Pierce שהייתה מקובלת עד אז.

### 3. ניתוח סדרות ההרוגים בתאונות

#### 3.1. הסדרות שנתחו

הסדרות עליהן בוצעו הניתוחים הסטטיסטיים הן סדרות חודשיות של הרוגים בתאונות, בתקופה מ-1/2003 עד 12/2008 (סה"כ בשטח מדינת ישראל, לא כולל יו"ש). כמקור הנתונים שימשו קבצי תאונות הדרכים של הלמ"ס, כאשר מספרי ההרוגים היו בהתאם להגדרה של הרוג בתאונה (נפטר תוך שלושים יום מתאריך התאונה).

הניתוח כלל 13 סדרות של נתונים שהן:

1. סה"כ מספר ההרוגים
2. מספר הרוגים בדרכים לא עירוניות

3. מספר הרוגים בדרכים עירוניות
  4. מספר הרוגים בתאונות עם נהגים צעירים (לפחות אחד מהנהגים המעורבים בתאונה הוא נהג צעיר בגיל 17-21)
  5. מספר הרוגים בתאונות עם רכב מקצועי (לפחות אחד מכלי הרכב המעורבים בתאונה הוא רכב משא מעל 4 טון)
  6. מספר הרוגים בתאונות רכב דו-גלגלי (לפחות אחד מכלי הרכב המעורבים בתאונה הוא אופנוע)
  7. מספר הרוגים הולכי רגל בדרכים העירוניות
  8. מספר הרוגים הולכי רגל בדרכים הלא עירוניות
  9. מספר הרוגים הולכי רגל במגזר הלא יהודי (קבוצת אוכלוסיה: "ערבים ואחרים", לא כולל "זרים")
  10. מספר הרוגים בתאונות רכב בודד בדרכים הלא עירוניות
  11. מספר הרוגים בתאונות חזית-חזית בדרכים הלא עירוניות
  12. מספר הרוגים בצמתים לא עירוניים (פרט לתאונות הולכי רגל)
  13. מספר הרוגים בצמתים עירוניים (פרט לתאונות הולכי רגל)
- סדרות אלה סומנו כ-  $s_1 - s_{13}$  בהתאמה.

### 3.2. שלב א: התאמת מודל מנייה ראשוני (עם התעלמות מתלות אפשרית) לסדרות המנותחות

#### 3.2.1. רשימת המשתנים המסבירים

להלן רשימת המשתנים המסבירים במודלים:

- ❖ משתנה offset - השווה ללוג מספר הימים בחודש (מסומן כ- logndays)
- ❖ מגמה – מיוצגת כמספר החודש (מסומן כ- time) מחולק ב-1000. החלוקה ב-1000 הינה בגלל תנאים שצריכים לקיים משתני המודל, כמתואר במאמר של (Davis & Wu (2009). מספר החודש נקבע להיות 1 ב- 1/2003. כך לדוגמה שווה מספר החודש ל-60 ב-12/2007 ול-61 ב-1/2008. משתנה זה סומן כ-trend.
- ❖ שבירת מגמה – רק עבור סדרה s9. שבירת מגמה בתצפית ה-12. יוצגה כמקסימום בין אפס ל- (מספר החודש פחות 12) מחולק ב-1000. משתנה זה סומן כ-trend12.
- ❖ עונתיות - זוגות של סינוסים וקוסינוסים בתדירויות שנתיות וחצי שנתיות.
  - משתנה P1:  $\cos(\pi \cdot \text{time} / 6)$  שזה למעשה  $\cos(2 \cdot \pi \cdot \text{time} / 12)$
  - משתנה P2:  $\sin(\pi \cdot \text{time} / 6)$  שזה למעשה  $\sin(2 \cdot \pi \cdot \text{time} / 12)$
  - משתנה P3:  $\cos(\pi \cdot \text{time} / 3)$  שזה למעשה  $\cos(2 \cdot \pi \cdot \text{time} / 6)$
  - ומשתנה P4:  $\sin(\pi \cdot \text{time} / 3)$  שזה למעשה  $\sin(2 \cdot \pi \cdot \text{time} / 6)$

❖ מלחמת לבנון השנייה - משתנה אינדיקטור (סומן כ- WAR). המשתנה מקבל את הערך 0, בחדשים שאינם חודשי מלחמה ו-1 בחדשי המלחמה (דהיינו, 7/2006 ו-8/2006).

בסעיף זה יובאו:

- תוצאות ראשוניות של המודלים, כולל מבחן לגבי מובהקות  $\alpha$  לבחינת הנחיצות של שימוש במודל NB1 או NB2.

- גרף המשווה בין ממוצע ההסתברויות הצפויות של שלושת המודלים האפשריים וההסתברויות הנצפות.

על בסיס תוצאות סעיף זה נבחר מודל מתאים (פואסוני / NB1 / NB2).

### 3.2.2 ערכי המשתנים המסבירים

להלן ערכי המשתנים המסבירים בתוספת מספר משתני עזר נוספים (מספר תצפית, שנה, חודש, מספר ימים).

Obs	obs	Year	Month	logndays	trend	trend12	War	p1	p2	p3	p4	ndays
1	1	2003	1	3.43399	0.001	0.000	0	0.86603	0.50000	0.5	0.86603	31
2	2	2003	2	3.33220	0.002	0.000	0	0.50000	0.86603	-0.5	0.86603	28
3	3	2003	3	3.43399	0.003	0.000	0	0.00000	1.00000	-1.0	0.00000	31
4	4	2003	4	3.40120	0.004	0.000	0	-0.50000	0.86603	-0.5	-0.86603	30
5	5	2003	5	3.43399	0.005	0.000	0	-0.86603	0.50000	0.5	-0.86603	31
6	6	2003	6	3.40120	0.006	0.000	0	-1.00000	0.00000	1.0	-0.00000	30
7	7	2003	7	3.43399	0.007	0.000	0	-0.86603	-0.50000	0.5	0.86603	31
8	8	2003	8	3.43399	0.008	0.000	0	-0.50000	-0.86603	-0.5	0.86603	31
9	9	2003	9	3.40120	0.009	0.000	0	-0.00000	-1.00000	-1.0	0.00000	30
10	10	2003	10	3.43399	0.010	0.000	0	0.50000	-0.86603	-0.5	-0.86603	31
11	11	2003	11	3.40120	0.011	0.000	0	0.86603	-0.50000	0.5	-0.86603	30
12	12	2003	12	3.43399	0.012	0.000	0	1.00000	-0.00000	1.0	-0.00000	31
13	13	2004	1	3.43399	0.013	0.001	0	0.86603	0.50000	0.5	0.86603	31
14	14	2004	2	3.36730	0.014	0.002	0	0.50000	0.86603	-0.5	0.86603	29
15	15	2004	3	3.43399	0.015	0.003	0	0.00000	1.00000	-1.0	0.00000	31
16	16	2004	4	3.40120	0.016	0.004	0	-0.50000	0.86603	-0.5	-0.86603	30
17	17	2004	5	3.43399	0.017	0.005	0	-0.86603	0.50000	0.5	-0.86603	31
18	18	2004	6	3.40120	0.018	0.006	0	-1.00000	0.00000	1.0	-0.00000	30
19	19	2004	7	3.43399	0.019	0.007	0	-0.86603	-0.50000	0.5	0.86603	31
20	20	2004	8	3.43399	0.020	0.008	0	-0.50000	-0.86603	-0.5	0.86603	31


Obs	obs	Year	Month	logndays	trend	trend12	War	p1	p2	p3	p4	ndays
21	21	2004	9	3.40120	0.021	0.009	0	-0.00000	-1.00000	-1.0	0.00000	30
22	22	2004	10	3.43399	0.022	0.010	0	0.50000	-0.86603	-0.5	-0.86603	31
23	23	2004	11	3.40120	0.023	0.011	0	0.86603	-0.50000	0.5	-0.86603	30
24	24	2004	12	3.43399	0.024	0.012	0	1.00000	-0.00000	1.0	-0.00000	31
25	25	2005	1	3.43399	0.025	0.013	0	0.86603	0.50000	0.5	0.86603	31
26	26	2005	2	3.33220	0.026	0.014	0	0.50000	0.86603	-0.5	0.86603	28
27	27	2005	3	3.43399	0.027	0.015	0	0.00000	1.00000	-1.0	0.00000	31
28	28	2005	4	3.40120	0.028	0.016	0	-0.50000	0.86603	-0.5	-0.86603	30
29	29	2005	5	3.43399	0.029	0.017	0	-0.86603	0.50000	0.5	-0.86603	31
30	30	2005	6	3.40120	0.030	0.018	0	-1.00000	0.00000	1.0	-0.00000	30
31	31	2005	7	3.43399	0.031	0.019	0	-0.86603	-0.50000	0.5	0.86603	31
32	32	2005	8	3.43399	0.032	0.020	0	-0.50000	-0.86603	-0.5	0.86603	31
33	33	2005	9	3.40120	0.033	0.021	0	-0.00000	-1.00000	-1.0	0.00000	30
34	34	2005	10	3.43399	0.034	0.022	0	0.50000	-0.86603	-0.5	-0.86603	31
35	35	2005	11	3.40120	0.035	0.023	0	0.86603	-0.50000	0.5	-0.86603	30
36	36	2005	12	3.43399	0.036	0.024	0	1.00000	-0.00000	1.0	-0.00000	31
37	37	2006	1	3.43399	0.037	0.025	0	0.86603	0.50000	0.5	0.86603	31
38	38	2006	2	3.33220	0.038	0.026	0	0.50000	0.86603	-0.5	0.86603	28
39	39	2006	3	3.43399	0.039	0.027	0	-0.00000	1.00000	-1.0	-0.00000	31
40	40	2006	4	3.40120	0.040	0.028	0	-0.50000	0.86603	-0.5	-0.86603	30
41	41	2006	5	3.43399	0.041	0.029	0	-0.86603	0.50000	0.5	-0.86603	31
42	42	2006	6	3.40120	0.042	0.030	0	-1.00000	0.00000	1.0	-0.00000	30
43	43	2006	7	3.43399	0.043	0.031	1	-0.86603	-0.50000	0.5	0.86603	31
44	44	2006	8	3.43399	0.044	0.032	1	-0.50000	-0.86603	-0.5	0.86603	31
45	45	2006	9	3.40120	0.045	0.033	0	-0.00000	-1.00000	-1.0	0.00000	30
46	46	2006	10	3.43399	0.046	0.034	0	0.50000	-0.86603	-0.5	-0.86603	31
47	47	2006	11	3.40120	0.047	0.035	0	0.86603	-0.50000	0.5	-0.86603	30
48	48	2006	12	3.43399	0.048	0.036	0	1.00000	-0.00000	1.0	-0.00000	31
49	49	2007	1	3.43399	0.049	0.037	0	0.86603	0.50000	0.5	0.86603	31
50	50	2007	2	3.33220	0.050	0.038	0	0.50000	0.86603	-0.5	0.86603	28
51	51	2007	3	3.43399	0.051	0.039	0	-0.00000	1.00000	-1.0	-0.00000	31
52	52	2007	4	3.40120	0.052	0.040	0	-0.50000	0.86603	-0.5	-0.86603	30
53	53	2007	5	3.43399	0.053	0.041	0	-0.86603	0.50000	0.5	-0.86603	31

Obs	obs	Year	Month	logndays	trend	trend12	War	p1	p2	p3	p4	ndays
54	54	2007	6	3.40120	0.054	0.042	0	-1.00000	0.00000	1.0	-0.00000	30
55	55	2007	7	3.43399	0.055	0.043	0	-0.86603	-0.50000	0.5	0.86603	31
56	56	2007	8	3.43399	0.056	0.044	0	-0.50000	-0.86603	-0.5	0.86603	31
57	57	2007	9	3.40120	0.057	0.045	0	-0.00000	-1.00000	-1.0	0.00000	30
58	58	2007	10	3.43399	0.058	0.046	0	0.50000	-0.86603	-0.5	-0.86603	31
59	59	2007	11	3.40120	0.059	0.047	0	0.86603	-0.50000	0.5	-0.86603	30
60	60	2007	12	3.43399	0.060	0.048	0	1.00000	-0.00000	1.0	-0.00000	31

### 3.2.3. נתונים תיאוריים והיסטוגרמות עבור 13 הסדרות

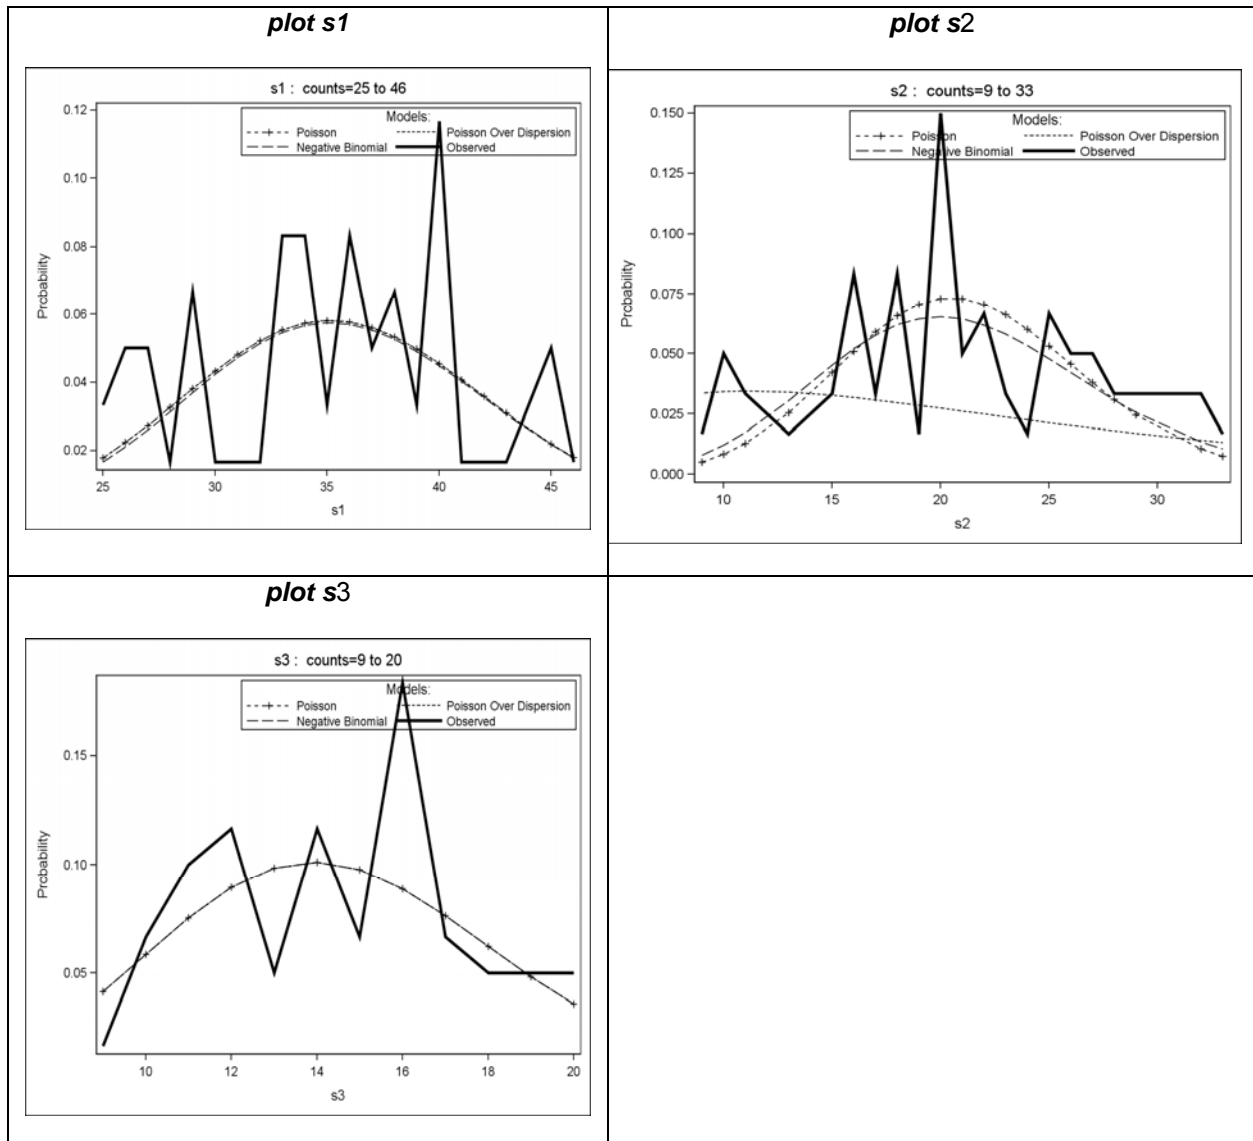
בסעיף זה מוצגת טבלה מסכמת. נבחנו גם היסטוגרמות של 13 הסדרות. כדוגמה, נציג רק היסטוגרמה של סדרה אחת שנבחרה שרירותית מתוך ה-13.

Variable	Minimum	5th Pctl	95th Pctl	Maximum
s1	24.0	25.5	46.5	58.0
s2	9.0	10.0	32.5	34.0
s3	6.0	9.5	20.0	25.0
s4	1.0	3.0	12.0	14.0
s5	1.0	2.0	13.0	17.0
s6	1.0	1.0	7.0	7.0
s7	1.0	3.0	14.5	18.0
s8	0.0	0.0	7.5	10.0
s9	0.0	1.0	7.0	8.0
s10	0.0	1.0	9.0	13.0
s11	0.0	0.5	8.5	11.0
s12	0.0	1.0	10.5	13.0
s13	0.0	0.0	5.0	6.0



### 3.2.4. תוצאות התאמת שלושת המודלים והשוואתם – לכל סדרה בנפרד

לכל אחת מהסדרות חושבו: השכיחויות, נבחנו תוצאות התאמת שלושת המודלים (כולל מבחנים לגבי מובהקות  $\alpha$  לבחירת ההתפלגות המתאימה למודל), שורטט גרף המשווה בין ממוצע ההסתברויות הצפויות של שלושת המודלים האפשריים וההסתברויות הנצפות וממצאים אלה סוכמו בטבלאות. הגרפים שורטטו לטווח הערכים בעלי שכיחות לא זניחה. שוב בחרנו לא להציג את כל הטבלאות, והגרפים, אלא רק לדווח על המסקנות ולהציג כדוגמה, את הגרפים עם ההשוואות עבור שלוש סדרות שנבחרו שרירותית. בכל גרף מוצגות ההתפלגויות המותאמות לפי שלוש ההתפלגויות שנבדקו.





### **3.2.5. מסקנות**

על בסיס ממצאי הסעיף הקודם התקבלו המסקנות הבאות לגבי המודלים המתאימים לכל סידרה:

- S1 - נבחר מודל פואסוני
- S2 - נבחר מודל בינומי שלילי
- S3 - נבחר מודל פואסוני
- S4 - נבחר מודל פואסוני
- S5 - נבחר מודל בינומי שלילי
- S6 - נבחר מודל פואסוני
- S7 - נבחר מודל פואסוני
- S8 - נבחר מודל פואסוני
- S9 - נבחר מודל פואסוני
- S10 - נבחר מודל פואסוני
- S11 - נבחר מודל פואסוני
- S12 - נבחר מודל בינומי שלילי
- S13 - נבחר מודל פואסוני

### **3.3. ניתוח סדרות השאריות מהמודלים שנבחרו**

לצורך הניתוח בסעיף זה ייצרנו תחילה את סדרת השאריות עבור כל סדרה, על פי המודל שנמצא כמתאים עבורה. יש לזכור מהמודל הותאם ללא התחשבות בתלות אפשרית בנתונים. בתכנת ה-SAS שברשותנו מוגדרים עבור Generalized linear models מספר סוגי שאריות. אנו בחרנו בחמישה סוגים מבין השאריות המוצעות שם. המשותף לסוגים אלה הוא שהם מתחשבים בכך שהשונות של המשתנה הנמדד תלויה בתוחלת שלו. בנוסף חלקם מנרמלים את השארית כך שלפחות אסימפטוטית תתקבלנה שאריות עם תוחלת אפס ושונות קבועה ושווה ל-1. מניתוח הקשרים בין הסדרות, הן על ידי חישוב הקורלציות ביניהן והן מתצוגה גרפית של תרשימי זוגות של סדרות עולה שהמתאם בין סדרות השאריות מאד גבוה, כך שמעשית אין הבדל באיזו סידרת שאריות נשתמש לניתוח. אנו בחרנו להמשיך את ניתוח התלות בין השאריות בעזרת סידרת שאריות deviance אשר מקובלת בניתוח סדרות של מודלים מהסוג GLZM ( Generalized linear models).

#### **3.3.1. הפלטים עבור 13 הסדרות**

חמש סדרות השאריות שיצרנו עבור כל מודל הן:

RESCHI - Pearson (chi) residuals

Deviance residuals - RESDEV

The likelihood residuals -RESLIK

Pearson residuals, standardized to have unit asymptotic variance - STDRESCHI

Deviance residuals, standardized to have unit asymptotic variance - STDRESDEV

עבור כל סדרת תאונות חושבו:

- מתאמים וסטטיסטיים פשוטים עבור סוגי שאריות של כל סדרת תאונות
- גרפים של זוגות מתוך חמשת סדרות השאריות שיצרנו לכל סידרה

לכל סידרת שאריות deviance נבחנו ארבעה גרפים:

- גרף הסדרה (the time series plot of the series)
- The sample autocorrelation function plot (ACF)
- The sample inverse autocorrelation function plot (IACF)
- The sample partial autocorrelation function plot (PACF)

כמו כן, חושב הסטטיסטי  $Q_m$ , עבור ערכי  $m$  נבחרים ונבדקה המובהקות עבור ערכים אלה.

הממצאים כהדגמה מוצגים שוב רק עבר סדרה 1. על המסקנות נדווח לגבי כל 13 הסדרות. מסקנות אלה מבוססות על הממצאים שנתקבלו לכל 13 הסדרות.


===== **s1 : simple statistics and correlation among residual types** =====

Simple Statistics						
Variable	N	Mean	Std Dev	Sum	Minimum	Maximum
RESCHI	60	0.0009831	0.96058	0.05899	-2.26304	2.67775
RESDEV	60	-0.02405	0.95622	-1.44299	-2.42538	2.51747
RESLIK	60	-0.02445	1.01538	-1.46679	-2.57447	2.71708
STDRESCHI	60	-0.0008505	1.01950	-0.05103	-2.42214	2.86622
STDRESDEV	60	-0.02742	1.01512	-1.64523	-2.59589	2.69466

Pearson Correlation Coefficients, N = 60 Prob >  r  under H0: Rho=0					
	RESCHI	RESDEV	RESLIK	STDRESCHI	STDRESDEV
RESCHI					
RESDEV					
RESLIK					
STDRESCHI					
STDRESDEV					

*Pearson Correlation Coefficients, N = 60*  
*Prob > |r| under H0: Rho=0*

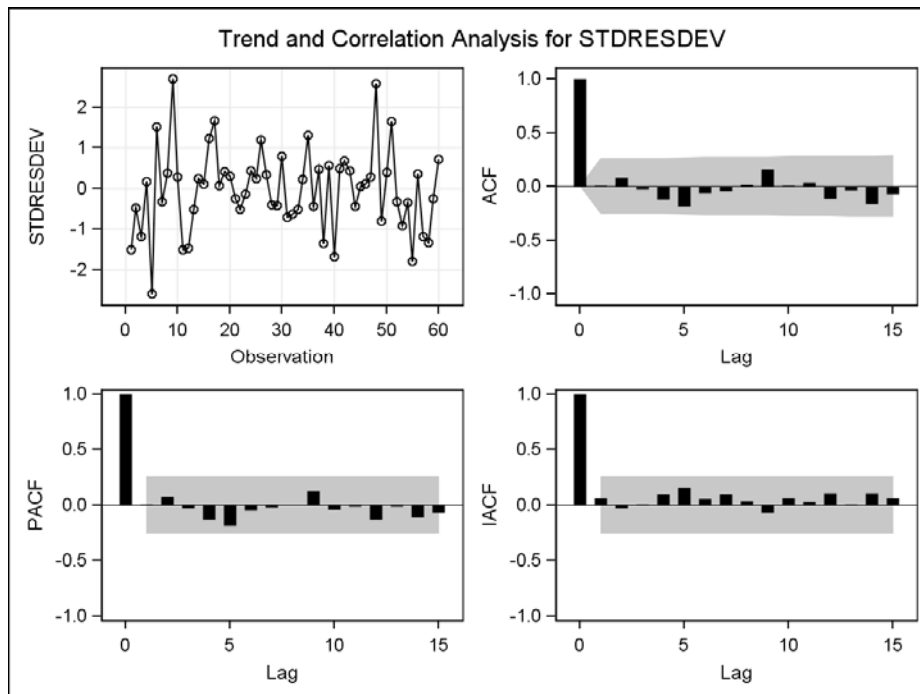
	<i>RESCHI</i>	<i>RESDEV</i>	<i>RESLIK</i>	<i>STDRESCHI</i>	<i>STDRESDEV</i>
<i>RESCHI</i>	1.00000	0.99917 <.0001	0.99901 <.0001	0.99975 <.0001	0.99882 <.0001
<i>RESDEV</i>	0.99917 <.0001	1.00000	0.99975 <.0001	0.99901 <.0001	0.99975 <.0001
<i>RESLIK</i>	0.99901 <.0001	0.99975 <.0001	1.00000	0.99935 <.0001	0.99999 <.0001
<i>STDRESCHI</i>	0.99975 <.0001	0.99901 <.0001	0.99935 <.0001	1.00000	0.99917 <.0001
<i>STDRESDEV</i>	0.99882 <.0001	0.99975 <.0001	0.99999 <.0001	0.99917 <.0001	1.00000



**S1 residuals**  
**The ARIMA Procedure**

<i>Name of Variable = STDRESDEV</i>	
<i>Mean of Working Series</i>	-0.02742
<i>Standard Deviation</i>	1.006622
<i>Number of Observations</i>	60

<i>Autocorrelation Check for White Noise</i>									
<i>To Lag</i>	<i>Chi-Square</i>	<i>DF</i>	<i>Pr &gt; ChiSq</i>	<i>Autocorrelations</i>					
6	4.13	6	0.6587	0.010	0.077	-0.029	-0.124	-0.189	-0.062
12	7.32	12	0.8356	-0.045	0.016	0.161	0.006	0.040	-0.115



### 3.3.2. מסקנות מניתוח שאריות המודלים

בדרך כלל, במודלים אין עדות לתלות בין השאריות, פרט לסדרות s6, s9 המרמזות על קיום תלות אפשרית. מאחר ועשינו כאן השוואות מרובות סביר שממצא זה מקרי. יש לציין שחוסר תלות בסדרות השאריות לא בהכרח מעיד שאין תלות בסדרות. שכן תלות יכולה לנבוע דרך תהליך נסתר. אפשרות זו נבדקה ותיאורה יובא בסעיף הבא על ידי מידול מתאים.

## 4. התאמת מודלים עם אפשרות לתלות בנתונים

### 4.1. השיטה

עבור כל סדרה הותאמו מספר מודלים אשר מתחשבים בתלות בנתונים. סעיף זה מתאר את תוצאות התאמת מודלים אלה, ואת המסקנות.

התאמת המודלים אשר פורטו לעיל, נעשתה בעזרת פרוצדורת GLIMMIX של SAS.

בהמשך, על בסיס מודלים אלה בוצעו הניתוחים שנועדו לענות על שאלות המחקר, דהיינו האם חלו שינויים במגמות הבטיחות ו/או ברמת הבטיחות בין שתי תקופות נתונות.

המודלים שהותאמו הם:

- מודל מותנה ("G-side"), שהוא המודל של (Davis & Wu (2009). מודל זה יסומן בתור G\_mod.

- שני מודלים שוליים ("R-side") SP(POW) ו- SP(EXP). מודלים אלה סומנו בתור: R\_mod\_P ו- R\_mod\_E בהתאמה.

באופן תיאורטי ניתן לקבל את ערך פרמטר התלות של כל אחד משני מודלים שוליים אלה מטרנספורמציה של הפרמטר במודל השני, אבל מכיוון שהאמדים מחושבים אמפירית, באמצעות אלגוריתמים נומריים, יתכן שיתקבלו ערכים שונים.

כפי שראינו בסעיף 3.2.5, ברוב הסדרות מתוך השלוש עשרה, ההתפלגות שנמצאה מתאימה הייתה הפואסונית. אולם, למספר קטן של סדרות המודל הבינומי השלילי נראה יותר מתאים. במקרים אלה, כאשר בוצעה התאמת המודלים **השוליים** היו בעיות חישוביות. (לא הייתה כל בעיה בהתאמת המודלים **המותנים** כאשר ההתפלגות המותאמת הייתה בינומית שלילית). כדי להתגבר על הבעיה התאמנו מודל שולי בהנחה שההתפלגות השולית היא פואסונית עם תלות, בדקנו בנוסף, מודל בינומי שלילי ללא תלות וערכנו השוואה של התוצאות להסקת המסקנות.

לכל סידרה התקבלו הטבלאות הבאות:

- Regression parameters model - פרמטרים של הרגרסיה ומובהקות הפרמטרים, עבור המודלים השונים של כל סדרה
- Cov parameters - פרמטרי תלות ושגיאות התקן שלהם
- Covariance parameter tests - מובהקות פרמטרי התלות

עבור שלוש הסדרות שלהן נמצא כמתאים נבחנו מודל בינומי שלילי (s2, s5, s12) נבחנו טבלאות עבור מודל פואסוני שהותאם להן, ובנוסף טבלאות המכילות את הגדלים המתייחסים למודל בינומי שלילי ללא תלות, ומודל בינומי שלילי מותנה. כדוגמה, יובאו הממצאים לטבלאות המתאימות לסדרות s1, s12.

נפרט את הגדלים המופיעים בכל פלט.

השדות המופיעים בטבלת Regression parameters model:

A\_Est – אמדי מקדמי הרגרסיה עבור המודל ללא תלות  
G\_Est – אמדי מקדמי הרגרסיה עבור המודל המותנה ("G-side")  
RP\_Est – אמדי מקדמי הרגרסיה עבור המודל השולי ("R-side") עם מבנה תלות SP(POW)  
RE\_Est – אמדי מקדמי הרגרסיה עבור המודל השולי ("R-side") עם מבנה תלות SP(EXP)  
A\_Pval – מובהקות מקדמי הרגרסיה עבור המודל ללא תלות  
G\_Pval – מובהקות מקדמי הרגרסיה עבור המודל המותנה ("G-side")  
RP\_Pval – מובהקות מקדמי הרגרסיה עבור המודל השולי ("R-side") עם מבנה תלות SP(POW)  
RE\_Pval – מובהקות מקדמי הרגרסיה עבור המודל השולי ("R-side") עם מבנה תלות SP(EXP)

השדות המופיעים בטבלת Cov parameters:

G\_CovP – שם פרמטר התלות עבור המודל המותנה ("G-side")  
G\_Est – אמד פרמטר התלות עבור המודל המותנה ("G-side")  
G\_SE – אמד שגיאת התקן של פרמטר התלות עבור המודל המותנה ("G-side")  
RP\_CovP – שם פרמטר התלות עבור המודל השולי ("R-side") עם מבנה תלות SP(POW)  
RP\_Est – אמד פרמטר התלות עבור המודל השולי ("R-side") עם מבנה תלות SP(POW)  
RP\_SE – אמד שגיאת התקן של פרמטר התלות עבור המודל השולי ("R-side") עם מבנה תלות SP(POW)  
RE\_CovP – שם פרמטר התלות עבור המודל השולי ("R-side") עם מבנה תלות SP(EXP)  
RE\_Est – אמד פרמטר התלות עבור המודל השולי ("R-side") עם מבנה תלות SP(EXP)  
RE\_SE – אמד שגיאת התקן של פרמטר התלות עבור המודל השולי ("R-side") עם מבנה תלות SP(EXP)

השדות המופיעים בטבלת Covariance parameter tests:

G\_Lab – שם המבחן לפרמטר התלות עבור המודל המותנה ("G-side")  
G\_Pval – מובהקות פרמטר התלות עבור המודל המותנה ("G-side")  
RP\_Lab – שם המבחן לפרמטר התלות עבור המודל השולי ("R-side") עם מבנה תלות SP(POW)

SP(POW) – מובהקות פרמטר התלות עבור המודל השולי ("R-side") עם מבנה תלות (SP(POW))  
 RE\_Lab – שם המבחן לפרמטר התלות עבור המודל השולי ("R-side") עם מבנה תלות (SP(EXP))  
 RE\_Pval – מובהקות פרמטר התלות עבור המודל השולי ("R-side") עם מבנה תלות (SP(EXP))

## 4.2. פלטים

להלן הממצאים עבור הסדרות s1, s12.

===== *S1 : regression parameters model = poisson* =====

Obs	Parameter	A_Est	G_Est	RP_Est	RE_Est	A_Pval
1	Intercept	0.25651	0.25651	0.25621	0.25621	0.00000
2	trend	-2.98161	-2.98161	-2.97127	-2.97127	0.01984
3	p1	-0.05047	-0.05047	-0.05058	-0.05058	0.10830
4	p2	-0.02619	-0.02619	-0.02617	-0.02617	0.39566
5	p3	-0.05356	-0.05356	-0.05367	-0.05367	0.07972
6	p4	0.01354	0.01354	0.01366	0.01366	0.66687
7	War	-0.40623	-0.40623	-0.40747	-0.40747	0.00692
8	Scale	1.00000	.	.	.	—

Obs	G_Pval	RP_Pval	RE_Pval
1	0.00000	0.00000	0.00000
2	0.01984	0.01605	0.01605
3	0.10830	0.09456	0.09456
4	0.39566	0.37814	0.37814
5	0.07972	0.06689	0.06689
6	0.66687	0.65047	0.65047
7	0.00692	0.00470	0.00470
8	.	.	.

**Cov parameters**

<i>Obs</i>	<i>G_CovP</i>	<i>G_Est</i>	<i>G_SE</i>	<i>RP_CovP</i>	<i>RP_Est</i>
1	Variance	1.4366E-18	.005516562	SP(POW)	0.01279
2	AR(1)	.000121380	.	Residual	0.90738

<i>Obs</i>	<i>RP_SE</i>	<i>RE_CovP</i>	<i>RE_Est</i>	<i>RE_SE</i>
1	0.13179	SP(EXP)	0.22942	0.54221
2	0.16569	Residual	0.90738	0.16569

**Covariance parameter tests**

<i>Obs</i>	<i>G_Lab</i>	<i>G_Pval</i>	<i>RP_Lab</i>	<i>RP_Pval</i>	<i>RE_Lab</i>	<i>RE_Pval</i>
1	Diagonal G	1	Conditional Independence	0.92267	Conditional Independence	0.46133

===== **S12 : regression parameters model = poisson** =====

<i>Obs</i>	<i>Parameter</i>	<i>A_Est</i>	<i>G_Est</i>	<i>RP_Est</i>	<i>RE_Est</i>	<i>A_Pval</i>
1	Intercept	-2.05718	-2.08190	-2.05659	-2.05718	0.00000
2	trend	0.07476	-0.25652	0.02678	0.07476	0.98449
3	p1	-0.26526	-0.26196	-0.26569	-0.26526	0.00638
4	p2	0.07150	0.07975	0.07141	0.07151	0.44381
5	p3	-0.08486	-0.07342	-0.08465	-0.08486	0.36158
6	p4	-0.03953	-0.04895	-0.04123	-0.03953	0.67946
7	War	-1.07288	-1.01039	-1.05401	-1.07287	0.07231



<i>Obs</i>	<i>Parameter</i>	<i>A_Est</i>	<i>G_Est</i>	<i>RP_Est</i>	<i>RE_Est</i>	<i>A_Pval</i>
8	Scale	1.00000	.	.	.	-

<i>Obs</i>	<i>G_Pval</i>	<i>RP_Pval</i>	<i>RE_Pval</i>
1	0.00000	0.00000	0.00000
2	0.95746	0.99564	0.98821
3	0.02898	0.03266	0.03804
4	0.49371	0.54937	0.56026
5	0.52642	0.48158	0.48771
6	0.68668	0.73876	0.75330
7	0.12915	0.16911	0.17163
8	.	.	.

**Cov parameters**

<i>Obs</i>	<i>G_CovP</i>	<i>G_Est</i>	<i>G_SE</i>	<i>RP_CovP</i>	<i>RP_Est</i>	<i>RP_SE</i>
1	Variance	0.15481	0.06757	SP(POW)	-0.03442	0.12897
2	AR(1)	-0.09307	0.30159	Residual	1.72973	0.31617

<i>Obs</i>	<i>RE_CovP</i>	<i>RE_Est</i>	<i>RE_SE</i>
1	SP(EXP)	0.00000	.
2	Residual	1.72850	0.31558

**Covariance parameter tests**

<i>Obs</i>	<i>G_Lab</i>	<i>G_Pval</i>	<i>RP_Lab</i>	<i>RP_Pval</i>	<i>RE_Lab</i>	<i>RE_Pval</i>
------------	--------------	---------------	---------------	----------------	---------------	----------------

<i>Obs</i>	<i>G_Lab</i>	<i>G_Pval</i>	<i>RP_Lab</i>	<i>RP_Pval</i>	<i>RE_Lab</i>	<i>RE_Pval</i>
1	Diagonal G	0.75594	Conditional Independence	0.78963	Conditional Independence	1

=====**S12 : regression parameters model = nb**=====

<i>Obs</i>	<i>Parameter</i>	<i>A_Est</i>	<i>G_Est</i>	<i>A_Pval</i>	<i>G_Pval</i>
1	Intercept	-2.06909	-2.08190	0.00000	0.00000
2	trend	0.41615	-0.25652	0.93335	0.95746
3	p1	-0.27331	-0.26196	0.02725	0.02898
4	p2	0.06980	0.07975	0.55973	0.49371
5	p3	-0.08387	-0.07342	0.47496	0.52642
6	p4	-0.05221	-0.04895	0.67527	0.68668
7	War	-1.07280	-1.01039	0.11164	0.12915
8	Dispersion	0.16172	.	-	.

**NB Cov parameters**

<i>Obs</i>	<i>G_CovP</i>	<i>G_Est</i>	<i>G_SE</i>
1	Variance	0.15481	0.06757
2	AR(1)	-0.09307	0.30159
3	Scale	0.00000	.

**NB Covariance parameter tests**

<i>Obs</i>	<i>G_Lab</i>	<i>G_Pval</i>
1	Diagonal G	0.75594

### 4.3. מסקנות

נמצאו: בסדרה 3 - מובהקות בשני המודלים השוליים; בסדרה 5 - מובהקות במודל שולי; בסדרה 11 - מובהקות במודל מותנה. הבדלים מזעריים בפרמטרים ובמובהקותם.

המסקנה היא שברוב הסדרות, בהינתן המשתנים המסבירים לא קיימת תלות בין התצפיות.

## 5. בחינת השינוי במגמה ובממוצע התאונות

### 5.1. רקע

בפרק זה נתייחס לבחינת מובהקות השינויים עבור 13 הסדרות. השאלה לגבי השינויים לגבי כל סדרה לחוד, היא האם חלו בסדרה שינויים במגמה או/ו ברמה בשנת 2008, בהשוואה לשנים 2003-2007, או בהשוואה לשנת 2007. נתוני 2003-2007, או 2007 הם נתוני ה"לפני", ונתוני 2008, הם ה"אחרי". עבור כל סדרה הותאמו מספר מודלים אשר מתחשבים בתלות בנתונים ובמודל ההסתברותי המתאים (פואסוני או בינומי שלילי). נתאר את תוצאות ההתאמה של מודלים אלה, ואת המסקנות המתקבלות על בסיס התאמתם לגבי השינוי במגמת תוחלת המופע היומי וברמתה. התאמת המודלים נעשתה בעזרת פרוצדורת GLIMMIX של SAS.

את מסקנותינו מהניתוח במחקר זה נשווה לאילו שקיבלו גיטלמן ודובא (2009), אשר ביצעו את הניתוחים ללא התחשבות בתלות האפשרית בתצפיות ועבור מודל פואסוני בלבד. נציין שהאפקט החודשי במחקרן בוטא במודל באמצעות משתנה קטגורי חודשי בעוד במודלים שבמחקר זה העדפנו להשתמש בזוגות של סינוסים וקוסינוסים בתדירויות שנתיות וחצי שנתיות, כפי שעשו, למשל, (Jung & Tremayne (2010).

### 5.2. בחינת שינוי במגמה

בסעיף זה נציג את מסקנות הניתוח שבוצע לכל סדרה מ-13 הסדרות כדי לענות על השאלה האם היה שינוי במגמת הסדרה ב-2008, לעומת המגמה בסדרה זו לפני 2008. השוואת המגמה ב-2008 למגמה בשנים לפני בוצעה באופן הבא: לנתוני הסדרה שכללו את שתי התקופות: "לפני" ו"אחרי", דהיינו השנים 2003-2008, הותאם אותו מודל כפי שהותאם עבור התקופה "לפני", ואשר הוצג בסעיף הקודם, אולם נוספו אליו שני משתנים מסבירים: משתנה המלחמה בעזה ומשתנה שינוי מגמה לחודשים של שנת 2008.

נציג את רשימת כל המשתנים המסבירים במודל מורחב זה:

❖ משתנה offset - השווה ללוג מספר הימים בחודש (מסומן כ- logndays)

❖ מגמה – מיוצגת כמספר החודש (מסומן כ- time) מחולק ב-1000. החלוקה ב-1000 הינה בגלל תנאים שצריכים לקיים משתני המודל, כמתואר במאמר של (Davis & Wu (2009. מספר החודש נקבע להיות 1 ב-1/2003. כך לדוגמה שווה מספר החודש ל-60 ב-12/2007 ול-61 ב-1/2008. משתנה זה סומן כ-trend.

- ❖ שבירת מגמה – רק עבור סדרה s9. שבירת מגמה בתצפית ה-12. יוצגה כמקסימום בין אפס ל- (מספר החודש פחות 12) מחולק ב-1000.} משתנה זה סומן כ-trend12.
  - ❖ עונתיות - זוגות של סינוסים וקוסינוסים בתדירויות שנתיות וחצי שנתיות.
    - משתנה P1:  $\cos(\pi \cdot \text{time}/6)$  שזה למעשה  $\cos(2 \cdot \pi \cdot \text{time}/12)$
    - משתנה P2:  $\sin(\pi \cdot \text{time}/6)$  שזה למעשה  $\sin(2 \cdot \pi \cdot \text{time}/12)$
    - משתנה P3:  $\cos(\pi \cdot \text{time}/3)$  שזה למעשה  $\cos(2 \cdot \pi \cdot \text{time}/6)$
    - ומשתנה P4:  $\sin(\pi \cdot \text{time}/3)$  שזה למעשה  $\sin(2 \cdot \pi \cdot \text{time}/6)$
  - ❖ מלחמת לבנון השנייה – משתנה אינדיקטור (סומן כ-WAR). המשתנה מקבל את הערך 0, בחודשים שאינם חודשי מלחמה ו-1 בחודשי המלחמה (דהיינו, 7/2006 ו-8/2006).
  - ❖ מלחמת המלחמה בעזה – משתנה אינדיקטור (סומן כ-WAR2). המשתנה מקבל את הערך 0, בחודשים שאינם חודשי מלחמה ו-1 בחודשי המלחמה. בנתונים המנותחים נכלל רק החודש שבו החלה המלחמה (דהיינו, 12/2008), מכיוון ששאר חודשי המלחמה הם לא בתקופת הניתוח.
  - ❖ משתנה שינוי מגמה "אחרי" - מיוצג כאפס עבור חודשים לפני 12/2007 (החודש ה-60 בנתונים) וכמספר החודש (time) פחות 60 מחולק ב-1000 לחודשים החל מ-12/2007. החלוקה ב-1000 הינה בגלל תנאים שצריכים לקיים משתני המודל, כמתואר במאמר של Davis & Wu (2009). משתנה זה סומן כ- trend60.  $\text{trend60} = \max(0, (\text{time} - 60)/1000)$ . לדוגמה, עבור 1/2008 שווה משתנה זה ל- (61-60)/1000.
  - מקדם משתנה שינוי המגמה אחרי (trend60) שווה להפרש מקדמי המגמה של לפני 2008 לעומת המקדם של שנת 2008. לכן, מובהקות אמד מקדם רגרסיה זה מעידה על שינוי מגמה. (מקדם המגמה ב-2008 שווה לסכום פרמטר זה ומקדם המגמה של התקופה "לפני"). עבור s9 שבה הייתה שבירת מגמה יש לחבר גם את trend12.
  - המודלים שהותאמו כאמור הם:
    - מודל מותנה ("G-side"), שהוא המודל של (Davis & Wu (2009);
    - שני מודלים שוליים ("R-side") (SP(POW) ו- SP(EXP)).
  - לכל סידרה התקבלו הטבלאות הבאות:
  - Regression parameters model - פרמטרים של הרגרסיה ומובהקות הפרמטרים, עבור המודלים השונים של כל סדרה;
  - Slopes before and after - אמדי המגמה "לפני" ו"אחרי".
- כפי שצוין, כאשר בוצעה התאמת המודלים **השוליים** להתפלגות בינומית היו בעיות חישוביות. (לא הייתה כל בעיה בהתאמת המודלים **המותנים** כאשר ההתפלגות המותאמת הייתה בינומית שלילית). לכן, גם בניתוח זה התאמנו מודל שולי בהנחה שההתפלגות השולית היא פואסונית עם תלות, בדקנו בנוסף, מודל בינומי שלילי ללא תלות וערכנו השוואה של התוצאות להסקת המסקנות.

עבור שלוש הסדרות שלהן התאים מודל בינומי שלילי נבחנו טבלאות מלאות עבור מודל פואסוני שהותאם להן ובנוסף, טבלאות המכילות את הגדלים המתייחסים למודל בינומי שלילי ללא תלות ומודל בינומי שלילי מותנה.

עבור הסדרות s11 s13 לא התכנס אף מודל שלוקח בחשבון תלות.

נפרט את הגדלים המופיעים בכל פלט.

השדות המופיעים בטבלת Regression parameters model:

A\_Est – אמדי מקדמי הרגרסיה עבור המודל ללא תלות.

G\_Est – אמדי מקדמי הרגרסיה עבור המודל המותנה ("G-side")

RP\_Est – אמדי מקדמי הרגרסיה עבור המודל השולי ("R-side") עם מבנה תלות SP(POW)

RE\_Est – אמדי מקדמי הרגרסיה עבור המודל השולי ("R-side") עם מבנה תלות SP(EXP)

A\_Pval – מובהקות מקדמי הרגרסיה עבור המודל ללא תלות

G\_Pval – מובהקות מקדמי הרגרסיה עבור המודל המותנה ("G-side")

RP\_Pval – מובהקות מקדמי הרגרסיה עבור המודל השולי ("R-side") עם מבנה תלות SP(POW)

RE\_Pval – מובהקות מקדמי הרגרסיה עבור המודל השולי ("R-side") עם מבנה תלות SP(EXP)

יש לזכור שאמד שינוי המגמה מופיע בשורה של המשתנה trend60. מקדם חיובי מובהק של trend60 פירושו הרעה במגמת 2008 לעומת המגמה ב-2007, ואילו מקדם שלילי מובהק של trend60 פירושו הטבה במגמת 2008 לעומת המגמה ב-2007.

השדות המופיעים בטבלת Slopes before and after:

A\_Bbef – אמד השיפוע "לפני", עבור המודל ללא תלות.

A\_Baft – אמד השיפוע "אחרי", כלומר, ב-2008, עבור המודל ללא תלות.

A\_Pbef – מובהקות השיפוע "לפני", עבור המודל ללא תלות.

A\_Paft – מובהקות השיפוע "אחרי", כלומר, ב-2008, עבור המודל ללא תלות.

אותם שדות מופיעים עבור המודל המותנה ("G-side") עם קידומת G במקום A, עבור המודל השולי ("R-side") עם מבנה תלות SP(POW) עם קידומת RP במקום A ועבור המודל השולי ("R-side") עם מבנה תלות SP(EXP) עם קידומת RE במקום A.

כדוגמה, שוב בחרנו שרירותית מתוך 13 הסדרות להציג את ממצאים המפורטים של הטבלאות רק עבור הסדרות s1, s12. כדי לא להעמיס בפלט, לא הוצגו אמדי שגיאות התקן, אולם כן הצגנו את ערכי Pvalues המתאימים.

יש לציין שברוב הסדרות נראה הבדל גדול באמדי המגמה כאשר משווים את ה"לפני" לעומת "אחרי". אולם, לפי Pvalues המתאימים, הבדלים אילו אינם בהכרח מובהקים סטטיסטית. אמד המגמה לתקופה "אחרי" אינו מבוסס על מספר חודשים גדול יחסית ולכן אמד שגיאתו גדול יחסית.

### 5.2.1 פלטים

===== *S1 : regression parameters model = poisson* =====

Obs	Parameter	A_Est	G_Est	RP_Est	RE_Est	A_Pval
1	Intercept	0.24944	0.24944	0.24939	0.24939	0.00000
2	trend	-2.59070	-2.59070	-2.58919	-2.58919	0.03031
3	p1	-0.04489	-0.04489	-0.04492	-0.04492	0.12310
4	p2	-0.02587	-0.02587	-0.02588	-0.02588	0.36611
5	p3	-0.03637	-0.03637	-0.03640	-0.03640	0.20173
6	p4	0.02562	0.02562	0.02563	0.02563	0.37246
7	War	-0.42247	-0.42247	-0.42267	-0.42267	0.00463
8	war2	0.58417	0.58417	0.58437	0.58437	0.00109
9	trend60	-5.66501	-5.66501	-5.67543	-5.67543	0.58527
10	Scale	1.00000	.	.	.	—

Obs	G_Pval	RP_Pval	RE_Pval
1	0.00000	0.00000	0.00000
2	0.03031	0.02492	0.02492
3	0.12310	0.10987	0.10987
4	0.36611	0.34892	0.34892
5	0.20173	0.18513	0.18513
6	0.37246	0.35485	0.35485
7	0.00463	0.00330	0.00330

Obs	G_Pval	RP_Pval	RE_Pval
8	0.00109	0.00069	0.00069
9	0.58527	0.57107	0.57107
10	.	.	.

===== **S1 : slopes before and after model = poisson** =====

Obs	A_Bbef	G_Bbef	RP_Bbef	RE_Bbef	A_Pbef	G_Pbef	RP_Pbef	RE_Pbef
1	-2.59070	-2.59070	-2.58919	-2.58919	0.030308	0.030308	0.024925	0.024925

Obs	A_Baft	G_Baft	RP_Baft	RE_Baft	A_Paft	G_Paft	RP_Paft	RE_Paft
1	-8.25571	-8.25571	-8.26462	-8.26462	0.39742	0.39742	0.38007	0.38007

===== **S12 : slopes before and after model = poisson** =====

Obs	A_Bbef	G_Bbef	RP_Bbef	RE_Bbef	A_Pbef	G_Pbef	RP_Pbef
1	-0.22706	-0.65916	-0.25115	-0.22707	0.95096	0.88145	0.95421

Obs	RE_Pbef	A_Baft	G_Baft	RP_Baft	RE_Baft	A_Paft
1	0.96110	-138.854	-132.575	-140.047	-138.854	.001753831

Obs	G_Paft	RP_Paft	RE_Paft
1	.006245428	.008154961	0.013077

===== **S12 : regression parameters model = nb** =====

Obs	Parameter	A_Est	G_Est	A_Pval	G_Pval
1	Intercept	-2.055	-2.068	0.00000	0.00000
2	trend	-0.090	-0.659	0.98460	0.88145
3	p1	-0.233	-0.223	0.04383	0.04383
4	p2	0.079	0.088	0.47776	0.41244
5	p3	-0.052	-0.044	0.63598	0.68407
6	p4	-0.096	-0.092	0.40511	0.40925
7	War	-0.994	-0.931	0.13530	0.15491
8	war2	1.948	1.945	0.02292	0.02195
9	trend60	-137.365	-131.916	0.00826	0.00893
10	Dispersion	0.146	.	-	.

===== **S12 :NB slopes before and after model = nb** =====

Obs	A_Bbef	G_Bbef	A_Pbef	G_Pbef	A_Baft	G_Baft
1	-0.089759	-0.65916	0.98460	0.88145	-137.455	-132.575

Obs	A_Paft	G_Paft
1	.005886738	.006245427

פרט לסדרה 12 בכל שאר הסדרות לא מצאנו שינוי מובהק במגמה. בסדרה זו נמצא שינוי בכיוון של ירידה (הפרש שלילי מובהק).

התוצאות שקיבלנו במחקר זה דומות מאד לאילו שהתקבלו במחקר קודם על סדרות אילו של גיטלמן ודובא (2009). הדמיון אינו מפתיע לאור העובדה שמחקר זה הראה כי לסדרות אילו יש הצדקה אמפירית להנחת אי-התלות בין התצפיות.



### 5.3. בחינת שינוי ממוצע קצב המופע היומי של התאונות

ההשוואות בסעיף זה נועדו לענות על השאלה האם היה שינוי מובהק ברמה בין שתי התקופות ( "לפני" לעומת "אחרי"). שינוי זה נבדק על ידי השוואת הממוצעים הגיאומטריים של תוחלת קצב המופע היומי של התאונות, בשתי התקופות. לשם הקיצור נכנה השוואה זאת כבחינת השינוי בקצב התאונות. אנו בדקנו האם היה שינוי בקצב הממוצע ב- 2008 לעומת 2003-2007 (לאחר תיקון למלחמה). ההשוואות נעשו בניכוי אפקט שתי המלחמות הכלולות בטווח השנים 2003-2008. כמו כן, בדקנו האם היה שינוי בקצב הממוצע ב- 2008 לעומת 2007.

בניתוח זה הותאם מודל הזהה למודל ה"לפני", שהוא המודל שהוצג בסעיף שכלל רק את נתוני 2003-2007, אולם נוספו אליו שלושת המשתנים המסבירים הבאים:

- בשל המלחמה בעזה נוסף: משתנה המלחמה בעזה;
  - כדי לאפשר גמישות מרבית בניתוח "אחרי", הותאמו שיפוע וחותר שונים לנתוני 2008.
- ההשוואות נעשו בניכוי אפקט שתי המלחמות הכלולות בטווח השנים 2003-2008. ניכוי זה נעשה על ידי מתן הערך 0 למשתני המלחמה, WAR ו-WAR2.
- נציג את רשימת כל המשתנים המסבירים במודל בסעיף זה (משתנים אלה זהים לאלה שבמודל שהוצג לשינוי מגמה ונוסף עליהם משתנה נוסף – השינוי בחותר ב-2008):

- ❖ משתנה offset - השווה ללוג מספר הימים בחודש (מסומן כ- logndays)
- ❖ מגמה – מיוצגת כמספר החודש (מסומן כ- time) מחולק ב-1000. החלוקה ב-1000 הינה בגלל תנאים שצריכים לקיים משתני המודל, כמתואר במאמר של (Davis & Wu (2009). מספר החודש נקבע להיות 1 ב- 1/2003. כך לדוגמה שווה מספר החודש ל-60 ב-12/2007 ול-61 ב-1/2008. משתנה זה סומן כ-trend.
- ❖ שבירת מגמה – רק עבור סדרה s9. שבירת מגמה בתצפית ה-12. יוצגה כמקסימום בין אפס ל- (מספר החודש פחות 12) מחולק ב-1000. משתנה זה סומן כ-trend12.
- ❖ עונתיות - זוגות של סינוסים וקוסינוסים בתדירויות שנתיות וחצי שנתיות.  
משתנה P1:  $\cos(\pi \cdot \text{time} / 6)$  שזה למעשה  $\cos(2 \cdot \pi \cdot \text{time} / 12)$   
משתנה P2:  $\sin(\pi \cdot \text{time} / 6)$  שזה למעשה  $\sin(2 \cdot \pi \cdot \text{time} / 12)$   
משתנה P3:  $\cos(\pi \cdot \text{time} / 3)$  שזה למעשה  $\cos(2 \cdot \pi \cdot \text{time} / 6)$   
ומשתנה P4:  $\sin(\pi \cdot \text{time} / 3)$  שזה למעשה  $\sin(2 \cdot \pi \cdot \text{time} / 6)$
- ❖ מלחמת לבנון השנייה – משתנה אינדיקטור (סומן כ- WAR). המשתנה מקבל את הערך 0, בחודשים שאינם חודשי מלחמה ו-1 בחודשי המלחמה (דהיינו, 7/2006 ו-8/2006).
- ❖ מלחמת המלחמה בעזה – משתנה אינדיקטור (סומן כ- WAR2). המשתנה מקבל את הערך 0, בחודשים שאינם חודשי מלחמה ו-1 בחודשי המלחמה. בנתונים המנותחים נכלל רק החודש

שבו החלה המלחמה (דהיינו, 12/2008), מכיוון ששאר חודשי המלחמה הם לא בתקופת הניתוח.

❖ משתנה שינוי מגמה אחרי – מיוצג כאפס עבור חודשים לפני 12/2007 (החודש ה-60 בנתונים) וכמספר החודש (time) פחות 60 מחולק ב-1000 לחודשים החל מ-12/2007. החלוקה ב-1000 הינה בגלל תנאים שצריכים לקיים משתני המודל, כמתואר במאמר של Davis & Wu (2009). משתנה זה סומן כ- trend60.  $trend60 = \max(0, (time - 60)/1000)$ . לדוגמה, עבור 1/2008 שווה משתנה זה ל- (61-60)/1000.

❖ משתנה שינוי בחותך ב-2008. משתנה זה שווה ל-1 בחודשי 2008 ו-0 בחודשים הקודמים ל-2008.

השוואות השינוי ברמה נעשו באופן הבא.

במודל השולי:

$$E(Y_t / \mu_t) = \mu_t$$

$$\log(\mu_t) = x_t^T \beta$$

$\log(\hat{\mu}_t) = x_t^T \hat{\beta}$  חושב על פי המודל שהותאם לזמן t, ומסמן את האמד עבור חודש כלשהו בתקופה "לפני", כמו למשל חודש ינואר 2003. נסמן ב-  $\log(\hat{\mu}_t^*) = x_t^{*T} \hat{\beta}$  את הערך המתאים אשר חושב על פי המודל שהותאם לזמן t, עבור חודש כלשהו בתקופה "אחרי", כמו למשל חודש ינואר 2008.

כאשר אנו ממצעים ערכים אלה על תקופות של שנה, מתבטלים למעשה האפקטים העונתיים המבוטאים על-ידי סינוסים וקוסינוסים במודלים. פרט לניכוי משתנה האינדיקטור של המלחמה WAR, אמד אפקט השינוי ניתן לביטוי על ידי:

$$\hat{D} = \frac{1}{12} \sum_t^* (\hat{\alpha}_j + \hat{\beta}_j t^*) - \frac{1}{12 * T} \sum_t (\hat{\alpha}_i + \hat{\beta}_i t)$$

כאשר הסכום הראשון (על ערכי t\*) הוא סכום על 12 חודשי התקופה אחרי (שנת 2008), ואילו t הוא סכום על חודשי התקופה "לפני" הכולל T שנים (שהיא בניתוח שלנו או השנים 2003-2007 או רק 2007). הפרש זה מהווה למעשה אמד להפרש הלוג של הממוצע הגיאומטרי של יחסי הסיכון היומי החודשיים. (כל חודש מאופיין ביחס סיכון יומי טיפוסי לו, ולכן ניתן לחשב ממוצע גיאומטרי של מאפיינים אלה). אם ההפרש שלילי מובהק פירושו שהיו פחות אירועים בשנה אחרי מאשר בתקופה "לפני" ולכן השנה המאוחרת מראה על שיפור.

כדי לקבל את האמדים בסקלה המקורית של "מספר אירועים ביום, חושב  $\exp(\hat{D})$  שהוא אמד ליחס הסיכון הממוצע (הגיאומטרי) השנתי בהשוואת שתי התקופות. כמו כן, חישבנו רווח סמך ליחס זה, (ברמת סמך של 0.95). כאשר רווח סמך כולל את הערך 1 פירושו שיחס הסיכון הממוצע לא השתנה,

בעוד כאשר גבול הרווח העליון קטן מ- 1 פירושו שב- 95% בטחון הסיכון בתקופה אחרי היה קטן יותר מזה שבתקופה הקודמת.

עבור המודל המותנה:

$$\begin{aligned} E(Y_t / \mu_t) &= \mu_t \\ \log(\mu_t) &= x_t^T \beta + v_t \\ E(Y_t / v_t) &= \exp(x_t^T \beta + v_t) \\ E(Y_t) &= \exp(x_t^T \beta + \frac{1}{2} \sigma_v^2) \end{aligned}$$

כמו שראינו עבור המודל השולי, גם כאן כאשר משווים את שתי התקופות מקבלים

$$\hat{D} = \frac{1}{12} \sum_t^* (\hat{\alpha}_j + \hat{\beta}_j t^*) - \frac{1}{12 * T} \sum_t (\hat{\alpha}_i + \hat{\beta}_i t)$$

כי הערך של שונות המרכיב החבוי מצטמצם כשלוקחים את ההפרש.

גם בהשוואות האלה, כפי שהוסבר למעלה, כאשר בוצעה התאמת המודלים **השוליים** להתפלגות בינומית היו בעיות חישוביות. (לא הייתה כל בעיה בהתאמת המודלים **המותנים** כאשר ההתפלגות המותאמת הייתה בינומית שלילית). כמו קודם, כדי להתגבר על הבעיה התאמנו מודל שולי בהנחה שההתפלגות השולית היא פואסונית עם תלות, בדקנו בנוסף, מודל בינומי שלילי ללא תלות וערכנו השוואה של התוצאות להסקת המסקנות.

עבור שלושת הסדרות שלהן מתאים מודל בינומי שלילי נבחנו טבלאות מלאות עבור מודל פואסוני שהותאם להן ובנוסף טבלאות המכילות את הגדלים המתייחסים למודל בינומי שלילי ללא תלות ומודל בינומי שלילי מותנה.

לכל סידרה התקבלו הטבלאות הבאות:

- Compare 2003-2007 to 2008 - יחס הסיכון הממוצע (הגיאומטרי) בהשוואת 2003-2007 ל- 2008 והמובהקות שלו, עבור המודלים השונים של כל סדרה;

- Compare 2007 to 2008 - יחס הסיכון הממוצע (הגיאומטרי) בהשוואת 2007 ל- 2008 והמובהקות שלו, עבור המודלים השונים של כל סדרה.

נפרט את הגדלים המופיעים בכל פלט.

A\_Rat08v0307 - יחס הסיכון הממוצע (הגיאומטרי) בהשוואת 2003-2007 ל- 2008. יחס גדול מ-1 באופן מובהק מצביע על סיכון גדול יותר באופן מובהק ב-2008 לעומת 2003-2007. חישוב עבור המודל ללא תלות.

A\_PRA08v0307 – מובהקות יחס הסיכון בהשוואת 2003-2007 ל- 2008. חישוב עבור המודל ללא תלות.

A\_Rat08v2007 - יחס הסיכון הממוצע (הגיאומטרי) בהשוואת 2007 ל- 2008. יחס גדול מ-1 באופן מובהק מצביע על סיכון גדול יותר באופן מובהק ב-2008 לעומת 2007. חישוב עבור המודל ללא תלות.

A\_PRA08v2007 – מובהקות יחס הסיכון בהשוואת 2007 ל- 2008. חישוב עבור המודל ללא תלות.

אותם שדות מופיעים עבור המודל המותנה ("G-side") עם קידומת G במקום A, עבור המודל השולי ("R-side") עם מבנה תלות SP(POW) עם קידומת RP במקום A ועבור המודל השולי ("R-side") עם מבנה תלות SP(EXP) עם קידומת RE במקום A.

בגלל חשיבות ממצאי סעיף זה, הצגנו הפעם את התוצאות לכל 13 הסדרות.

### **5.3.1. פלטים**

**===== S1 : Compare 2003 - 2007 to 2008 model = poisson**

Obs	A_Rat08v0307	G_Rat08v0307	RP_Rat08v0307	RE_Rat08v0307
1	0.89304	0.89304	0.89305	0.89305

Obs	A_PRA08v0307	G_PRA08v0307	RP_PRA08v0307	RE_PRA08v0307
1	0.052794	0.052794	0.042357	0.042357

**===== S1 : Compare 2007 to 2008 model = poisson =====**

Obs	A_Rat08v2007	G_Rat08v2007	RP_Rat08v2007	RE_Rat08v2007
1	0.96083	0.96083	0.96084	0.96084

Obs	A_PRA08v2007	G_PRA08v2007	RP_PRA08v2007	RE_PRA08v2007
1	0.54929	0.54929	0.53021	0.53021

**===== S2 : Compare 2003 - 2007 to 2008 model = poisson**

Obs	A_Rat08v0307	G_Rat08v0307	RP_Rat08v0307	RE_Rat08v0307
1	0.84395	0.84313	0.84352	0.84395

Obs	A_P Rat08v0307	G_P Rat08v0307	RP_P Rat08v0307	RE_P Rat08v0307
1	0.028481	0.044525	0.049698	0.062038

===== **S2 : Compare 2007 to 2008 model = poisson** =====

Obs	A_Rat08v2007	G_Rat08v2007	RP_Rat08v2007	RE_Rat08v2007
1	0.91314	0.91119	0.91253	0.91314

Obs	A_P Rat08v2007	G_P Rat08v2007	RP_P Rat08v2007	RE_P Rat08v2007
1	0.30242	0.33697	0.35383	0.37970

===== **S2 : Compare 2003 - 2007 to 2008 model = nb** =====

Obs	A_Rat08v0307	G_Rat08v0307	A_P Rat08v0307	G_P Rat08v0307
1	0.84392	0.84314	0.057792	0.045651

===== **S2 : Compare 2007 to 2008 model = nb** =====

Obs	A_Rat08v2007	G_Rat08v2007	A_P Rat08v2007	G_P Rat08v2007
1	0.91144	0.91110	0.36349	0.33878

===== **S3 : Compare 2003 - 2007 to 2008 model = poisson** =====

Obs	A_Rat08v0307	G_Rat08v0307	RP_Rat08v0307	RE_Rat08v0307
1	0.96619	0.96619	0.96953	0.96953

Obs	A_Prat08v0307	G_Prat08v0307	RP_Prat08v0307	RE_Prat08v0307
1	0.69985	0.69985	0.73957	0.73957

===== **S3 : Compare 2007 to 2008 model = poisson** =====

Obs	A_Rat08v2007	G_Rat08v2007	RP_Rat08v2007	RE_Rat08v2007
1	1.03079	1.03079	1.02774	1.02774

Obs	A_Prat08v2007	G_Prat08v2007	RP_Prat08v2007	RE_Prat08v2007
1	0.76711	0.76711	0.79636	0.79636

===== **S4 : Compare 2003 - 2007 to 2008 model = poisson** =====

Obs	A_Rat08v0307	G_Rat08v0307	RP_Rat08v0307	RE_Rat08v0307
1	0.90204	0.90204	0.90208	0.90208

Obs	A_Prat08v0307	G_Prat08v0307	RP_Prat08v0307	RE_Prat08v0307
1	0.44805	0.44805	0.44264	0.44264

===== **S4 : Compare 2007 to 2008 model = poisson** =====

<i>Obs</i>	<i>A_Rat08v2007</i>	<i>G_Rat08v2007</i>	<i>RP_Rat08v2007</i>	<i>RE_Rat08v2007</i>
1	1.01017	1.01017	1.00902	1.00902

<i>Obs</i>	<i>A_P Rat08v2007</i>	<i>G_P Rat08v2007</i>	<i>RP_P Rat08v2007</i>	<i>RE_P Rat08v2007</i>
1	0.94846	0.94846	0.95361	0.95361

===== **S5 : Compare 2003 - 2007 to 2008 model = poisson** =====

<i>Obs</i>	<i>A_Rat08v0307</i>	<i>G_Rat08v0307</i>	<i>RP_Rat08v0307</i>	<i>RE_Rat08v0307</i>
1	0.95322	0.95288	0.94787	0.95322

<i>Obs</i>	<i>A_P Rat08v0307</i>	<i>G_P Rat08v0307</i>	<i>RP_P Rat08v0307</i>	<i>RE_P Rat08v0307</i>
1	0.73474	0.75869	0.69761	0.77788

===== **S5 : Compare 2007 to 2008 model = poisson** =====

<i>Obs</i>	<i>A_Rat08v2007</i>	<i>G_Rat08v2007</i>	<i>RP_Rat08v2007</i>	<i>RE_Rat08v2007</i>
1	1.07434	1.06933	1.06060	1.07434

<i>Obs</i>	<i>A_P Rat08v2007</i>	<i>G_P Rat08v2007</i>	<i>RP_P Rat08v2007</i>	<i>RE_P Rat08v2007</i>
1	0.65953	0.71119	0.71107	0.71378

===== **S5 : Compare 2003 - 2007 to 2008 model = nb** =====

<i>Obs</i>	<i>A_Rat08v0307</i>	<i>G_Rat08v0307</i>	<i>A_Prat08v0307</i>	<i>G_Prat08v0307</i>
1	0.94974	0.94959	0.75991	0.76180

===== **S5 : Compare 2007 to 2008 model = nb** =====

<i>Obs</i>	<i>A_Rat08v2007</i>	<i>G_Rat08v2007</i>	<i>A_Prat08v2007</i>	<i>G_Prat08v2007</i>
1	1.07075	1.07058	0.72462	0.72843

===== **S6 : Compare 2003 - 2007 to 2008 model = poisson** =====

<i>Obs</i>	<i>A_Rat08v0307</i>	<i>G_Rat08v0307</i>	<i>RP_Rat08v0307</i>	<i>RE_Rat08v0307</i>
1	1.22439	1.22439	1.22466	1.22466

<i>Obs</i>	<i>A_Prat08v0307</i>	<i>G_Prat08v0307</i>	<i>RP_Prat08v0307</i>	<i>RE_Prat08v0307</i>
1	0.22592	0.22592	0.14750	0.14750

===== **S6 : Compare 2007 to 2008 model = poisson** =====

<i>Obs</i>	<i>A_Rat08v2007</i>	<i>G_Rat08v2007</i>	<i>RP_Rat08v2007</i>	<i>RE_Rat08v2007</i>
1	1.26614	1.26614	1.26660	1.26660

<i>Obs</i>	<i>A_Prat08v2007</i>	<i>G_Prat08v2007</i>	<i>RP_Prat08v2007</i>	<i>RE_Prat08v2007</i>
1	0.23044	0.23044	0.15091	0.15091



===== **S7 : Compare 2003 - 2007 to 2008 model = poisson** =====

Obs	A_Rat08v0307	G_Rat08v0307	RP_Rat08v0307	RE_Rat08v0307
1	0.87011	0.87146	0.86983	0.86983

Obs	A_PRad08v0307	G_PRad08v0307	RP_PRad08v0307	RE_PRad08v0307
1	0.25493	0.30699	0.30722	0.30722

===== **S7 : Compare 2007 to 2008 model = poisson** =====

Obs	A_Rat08v2007	G_Rat08v2007	RP_Rat08v2007	RE_Rat08v2007
1	0.97798	0.97893	0.97641	0.97641

Obs	A_PRad08v2007	G_PRad08v2007	RP_PRad08v2007	RE_PRad08v2007
1	0.87324	0.88986	0.87810	0.87810

===== **S8 : Compare 2003 - 2007 to 2008 model = poisson** =====

Obs	A_Rat08v0307	G_Rat08v0307	RP_Rat08v0307	RE_Rat08v0307
1	0.97880	0.98150	0.97541	0.97880

Obs	A_PRad08v0307	G_PRad08v0307	RP_PRad08v0307	RE_PRad08v0307
1	0.90987	0.92222	0.89225	0.91282

===== **S8 : Compare 2007 to 2008 model = poisson** =====

Obs	A_Rat08v2007	G_Rat08v2007	RP_Rat08v2007	RE_Rat08v2007
1	1.29549	1.29787	1.28688	1.29549

Obs	A_P Rat08v2007	G_P Rat08v2007	RP_P Rat08v2007	RE_P Rat08v2007
1	0.24440	0.24591	0.24298	0.26025

===== **S9 : Compare 2003 - 2007 to 2008 model = poisson** =====

Obs	A_Rat08v0307	G_Rat08v0307	RP_Rat08v0307	RE_Rat08v0307
1	1.03828	1.03828	1.03901	1.03828

Obs	A_P Rat08v0307	G_P Rat08v0307	RP_P Rat08v0307	RE_P Rat08v0307
1	0.82795	0.82795	0.75741	0.78212

===== **S9 : Compare 2007 to 2008 model = poisson** =====

Obs	A_Rat08v2007	G_Rat08v2007	RP_Rat08v2007	RE_Rat08v2007
1	1.28094	1.28094	1.28086	1.28094

Obs	A_P Rat08v2007	G_P Rat08v2007	RP_P Rat08v2007	RE_P Rat08v2007
1	0.23448	0.23448	0.097569	0.13031

===== **S10 : Compare 2003 - 2007 to 2008 model = poisson** =====

Obs	A_Rat08v0307	G_Rat08v0307	RP_Rat08v0307	RE_Rat08v0307
1	0.79098	0.79098	0.79062	0.79098

Obs	A_P Rat08v0307	G_P Rat08v0307	RP_P Rat08v0307	RE_P Rat08v0307
1	0.14753	0.14753	0.12669	0.13831

===== **S10 : Compare 2007 to 2008 model = poisson** =====

Obs	A_Rat08v2007	G_Rat08v2007	RP_Rat08v2007	RE_Rat08v2007
1	0.77576	0.77576	0.77637	0.77576

Obs	A_P Rat08v2007	G_P Rat08v2007	RP_P Rat08v2007	RE_P Rat08v2007
1	0.16340	0.16340	0.14384	0.15379

===== S11 : Compare 2003 - 2007 to 2008 model = poisson

Obs	A_Rat08v0307	G_Rat08v0307	RP_Rat08v0307	RE_Rat08v0307
1	0.84951	.	.	.

Obs	A_P Rat08v0307	G_P Rat08v0307	RP_P Rat08v0307	RE_P Rat08v0307
1	0.36473	.	.	.

===== S11 : Compare 2007 to 2008 model = poisson =====

Obs	A_Rat08v2007	G_Rat08v2007	RP_Rat08v2007	RE_Rat08v2007
1	0.93420	.	.	.

Obs	A_P Rat08v2007	G_P Rat08v2007	RP_P Rat08v2007	RE_P Rat08v2007
1	0.73834	.	.	.

===== S12 : Compare 2003 - 2007 to 2008 model = poisson

Obs	A_Rat08v0307	G_Rat08v0307	RP_Rat08v0307	RE_Rat08v0307
1	0.40288	0.41346	0.39952	0.40288

Obs	A_P Rat08v0307	G_P Rat08v0307	RP_P Rat08v0307	RE_P Rat08v0307

Obs	<i>A_P Rat08v0307</i>	<i>G_P Rat08v0307</i>	<i>RP_P Rat08v0307</i>	<i>RE_P Rat08v0307</i>
1	.000593077	.002068721	.003645720	.006424128

==== **S12 : Compare 2007 to 2008 model = poisson** =====

Obs	<i>A_Rat08v2007</i>	<i>G_Rat08v2007</i>	<i>RP_Rat08v2007</i>	<i>RE_Rat08v2007</i>
1	0.40393	0.41836	0.40095	0.40393

Obs	<i>A_P Rat08v2007</i>	<i>G_P Rat08v2007</i>	<i>RP_P Rat08v2007</i>	<i>RE_P Rat08v2007</i>
1	.001256899	.004758540	.006366790	0.010486

==== **S12 : Compare 2003 - 2007 to 2008 model = nb** =====

Obs	<i>A_Rat08v0307</i>	<i>G_Rat08v0307</i>	<i>A_P Rat08v0307</i>	<i>G_P Rat08v0307</i>
1	0.40686	0.41346	.002255779	.002068720

==== **S12 : Compare 2007 to 2008 model = nb** =====

Obs	<i>A_Rat08v2007</i>	<i>G_Rat08v2007</i>	<i>A_P Rat08v2007</i>	<i>G_P Rat08v2007</i>
1	0.40555	0.41836	.004518369	.004758537

==== **S13 : Compare 2003 - 2007 to 2008 model = poisson** =====

Obs	<i>A_Rat08v0307</i>	<i>G_Rat08v0307</i>	<i>RP_Rat08v0307</i>	<i>RE_Rat08v0307</i>
1	0.97740	.	.	.

Obs	<i>A_P Rat08v0307</i>	<i>G_P Rat08v0307</i>	<i>RP_P Rat08v0307</i>	<i>RE_P Rat08v0307</i>
1	0.92894	.	.	.

==== **S13 : Compare 2007 to 2008 model = poisson** =====

Obs	<i>A_Rat08v2007</i>	<i>G_Rat08v2007</i>	<i>RP_Rat08v2007</i>	<i>RE_Rat08v2007</i>

Obs	A_Rat08v2007	G_Rat08v2007	RP_Rat08v2007	RE_Rat08v2007
1	0.71314	.	.	.

Obs	A_PRA08v2007	G_PRA08v2007	RP_PRA08v2007	RE_PRA08v2007
1	0.22870	.	.	.

### 5.3.2. מסקנות לגבי שינוי הקצב

ברוב הסדרות לא נמצא שינוי מובהק סטטיסטית בקצב הממוצע, כאשר משווים את התקופה "לפני" עם התקופה "אחרי". הממצא אינו מפתיע שכן נתוני הסדרות יחסית קטנים ולכן, עוצמת המבחנים הסטטיסטיים אינה גדולה, בפרט כשהשוואה היא בין שתי שנים.

ההבדלים המובהקים שנמצאו היו עבור הסדרות שבהן המספרים היו גדולים יחסית (לא התייחסו לקטגוריות פרטניות). לכן, ראינו תוצאה מובהקת סטטיסטית (של ירידה) כאשר השוואה הייתה בין השנים 2003-2007 לבין 2008 בסדרה שכללה את סה"כ מספר ההרוגים (s1) ובסדרה של סה"כ מספר ההרוגים בדרכים הלא עירוניות (s2). עבור שתי סדרות אלה התקבלה תוצאה מובהקת הן בניתוח שבו הייתה הנחת אי תלות והן בניתוחים שבהם נלקחה בחשבון אפשרות התלות. בשני המקרים המובהקות שהתקבלה הייתה גדולה יותר (Pvalue) קטן יותר כאשר הייתה הנחת אי תלות.

פרט לשתי הסדרות שכללו מספרים גדולים יחסית, גם בסדרה (s12) של מספר ההרוגים בצמתים לא עירוניים (פרט לתאונות הולכי רגל), מצאנו תוצאה מובהקת סטטיסטית של ירידה משמעותית גדולה יחסית בקצב, הן בהשוואה של השנים 2003-2007 מול 2008 והן בהשוואה של 2007 מול 2008.

כצפוי, היו הבדלים קטנים מאד בין הממצאים על בסיס המודלים "הפשטניים" שהתבססו על הנחת אי תלות לעומת המודלים האחרים. שכן התלות שמצאנו ב-13 הסדרות לא הייתה חזקה יחסית.

המסקנה היא שברוב הסדרות, בהינתן המשתנים המסבירים לא קיימת תלות בין התצפיות.

## **סיכום חלק ראשון**

תרומתו העיקרית של החלק הראשון בעבודה זו אינה רק במסקנות הניתוח המתייחסות ל-13 הסדרות של הרוגים בשנים 2003-2008 שבו בחנו את השינוי ב-2008. התרומה המשמעותית היא בעיקר בהצגת הסבר מפורט על השיטות העדכניות שאותן מומלץ לאמץ בהמשך לבחינת שינויים בסדרות מסוג זה.

## חלק שני - תרשימי בקרה (Control Charts)

### 6. התפתחות שיטות סטטיסטיות לצרכי בקרת התהליכים

#### 6.1. רקע מהספרות

תחומי מחקר שונים עוסקים בשאלה כיצד לגלות שינויים בתהליך. השיטות הסטטיסטיות אשר פותחו ואשר עדיין ממשיכים לפתח משמשות לא רק בתחום של סטטיסטיקה תעשייתית ככלי לבקרת איכות של תהליכי ייצור, אלא בתחומים רבים ומגוונים, כמו זיהוי התפשטות מחלות (Bio-surveillance), גילוי מקרי תרמית (Fraud Detection) וכן, שינויי מגמות במעקב אחרי תאונות דרכים, שזה הנושא בעל העניין בעבודה זו.

עבודות עדכניות בנושא של גילוי שינויים על ידי שיטות סטטיסטיות פורסמו לאחרונה בסדרת מאמרים ב-Technometrics (2010). המאמרים הללו דנו בשני התחומים של זיהוי התפשטות מחלות (Bio-surveillance), וגילוי מקרי תרמית (Fraud Detection). השיטות הסטטיסטיות המוצגות במאמרים אלה ישימות לתחומים אחרים ובין השאר לתחום שהוא בעל העניין במחקר זה, דהיינו היפגעות בתאונות הדרכים.

ניתן לסווג את שיטות הניתוח לשתי קטגוריות. האחת הנקראת online, שבה המעקב הוא תוך כדי התהליך ובה מייחסים חשיבות מרובה לשקלול מתאים בין עיכוב בגילוי לבין אזעקת שווא, והשנייה off-line שבה בוחנים נתוני עבר כדי להעריך האם חל שינוי.

השיטה הקלאסית למעקב אחרי תהליכים היא תרשימי הבקרה (CC - Control Charts) הנקראים על שם Shewhart. נקודות המתאימות לתוצאות בתהליך אשר נמצאות בתרשימים אלה מחוץ לגבולות הבקרה נחשבות כתוצאות חריגות. חשיבות קריטית בבניית התרשימים יש להגדרת גבולות הבקרה. גבולות "צרים מדי" מגדילים את הסיכוי ל- False Positive, בעוד גבולות ליברליים עלולים להביא לסיכוי גדול שתהליך אשר אינו בבקרה לא יאובחן ככזה (False Negative). תרשימי הבקרה מסוג Shewhart נועדו בעיקר לניתוח אוסף (batch) של תוצאות. יעילותם לפיקוח על תצפיות בודדות או לפיקוח רציף מוגבלת. ניתן בעזרתם לגלות סטיות גדולות בתהליך, אך לא סטיות קטנות.

כהשלמה לתרשימים מסוג Shewhart פותחו התרשימים מסוג Cusum (Cumulative Sums) וגם התרשימים מסוג EWMA (Exponential Weighted Moving Averages). רגישותם של תרשימים אלה גבוהה יותר מזו של תרשימי Shewhart לגילוי סטיות קטנות.

תרשימי CUSUM מבוססים על ניטור סידרתי של סכום הסטיות של ערכי התהליך ממטרה. שימוש בתרשימים אלה מאפשר פיקוח בזמן אמתי (real-time) על התהליך ומאפשר זיהוי של הדרדרות בתהליך, שהיה בבקרה. תרשימי CUSUM מיועד לגלות סטיות מהמוצע של התהליך בגודל של 0.5-2 סטיות תקן. לפי (Lukas, 1976), מהירות הגילוי בעזרת CUSUM (עם V-MASK) של סטייה בגודל סטיית תקן אחת, תהיה במהירות הגדולה לפחות פי ארבע מתרשימי Shewhart. ב CUSUM שינויים בתהליך גורמים לשינוי הזווית של התרשימים, בנקודה בה חל השינוי. אולם, תרשימי CUSUM איטיים בגילוי שינויים גדולים לעומת תרשימי Shewhart, וכן לא קל לפרש את התבניות הנוצרות על ידי התרשימים האלה מאחר והסכומים המצטברים מתואמים (אינם בלתי תלויים). כפי שנראה בדוגמאות אשר במחקר זה, יתרונם קטן יחסית בהשוואה לתרשימי Shewhart, בפרט כאשר משלימים את תרשימי Shewhart במבחנים משלימים כפי שהוצעו על ידי Nelson (1984). לכן, מומלץ להשתמש בתרשימי CUSUM **כתוספת** לתרשימי Shewhart, ובכך ניתן יהיה לגלות הן שינויים גדולים והן קטנים בתהליך.

תרשימי מסוג EWMA הינו תרשימי בקרה המשתמש בכל היסטוריית התהליך, אם כי לא במשקל זהה, אלא במשקל הדועך גיאומטרית. הוא עמיד בפני חוסר נורמאליות של המשתנה הנבדק, אם כי יש לסוג זה גרסה המתאימה במיוחד למשתנים בעלי התפלגות פואסונית. עבור תרשימי EWMA יש לקבוע את מידת השקלול של תצפיות העבר. ככל שמשקל זה גבוה יותר כך גדלה השפעת הנתונים

ההיסטוריים. קיימות גישות שונות לקביעת משקל זה. גישה אחת, של Hunter (1986), היא להשאיר את השיפוט למנתח התהליך. גישה אחרת היא לאמוד את המשקל על ידי פרוצדורת מזעור סכום ריבועים, כאשר מניחים שהנתונים נוצרו על פי מודל EWMA. במקרה זה מודל ה-EWMA מספק תחזית של התהליך המהווה בסיס לבקרת תהליך דינמית. ישנה גישה אחרת, על פיה נקבע השקלול על פי ARL (Average Run Length), שהוא תוחלת מספר הנקודות עד לגילוי שינוי בתהליך. רצוי כמובן שמספר זה יהיה קטן כאשר יחול שינוי וגדול כאשר אין למעשה שום שינוי.

מכיוון שתרשים ה-EWMA מבוסס, בכל נקודה, הן על ערך התהליך הנוכחי והן על ערכים קודמים, בדומה ל-CUSUM, הוא רגיש לשינויים קטנים בממוצע התהליך, ולא לשינויים גדולים אשר מגלים תרשימי Shewhart. כמו כן, בדומה ל-CUSUM, גם ב-EWMA קשה לפרש את התבניות הנוצרות ע"י התרשים מכיוון שהסכומים המצטברים יכולים להיות מאוד מתואמים. גם עבור תרשימים מסוג EWMA, בדומה ל-CUSUM, יש הממליצים להוסיף לתרשים מסוג Shewhart, כדי לאפשר גילויים גם של שינויים גדולים וגם של קטנים בתהליך. במאמר (Yahav et al, 2011), מציגים המחברים שילוב של שלוש השיטות: תרשימי Shewhart, תרשימי CUSUM ותרשימי EWMA. השיטה בנויה כך שהשילוב לא יגדיל את ההסתברות של False Alarm מעבר לערך מסוים שנקבע מראש.

לבניית גבולות הבקרה בתרשימי הבקרה, יש צורך לדעת את הפרמטרים של התהליך. מאחר וברוב המקרים פרמטרים אלה אינם ידועים, משתמשים באמדים הנאמדים על בסיס מדגם ייחוס של התהליך הנחשב כמייצג את התהליך כאשר הוא בבקרה. מספר מחקרים בוצעו לגבי האפקט של האמידה במקום ידיעת הפרמטרים על ביצועם של תרשימי הבקרה (לדוגמה, Testik 2006).

הרחבות של השיטות הסטטיסטיות לבעיות מעשיות נעשו בכמה כיוונים. למשל, טיפול בתלות הסדרתית. בבקרת האיכות הקלסית ניתן להניח שאין תלות בנתונים. כלומר, תכונת כל batch לא תלויה בנתונים האחרים. אולם, מעשית, במעקב אחרי תהליכים בזמן, כאשר המרווח בין הדגימות קצר, הנחה זו אינה סבירה. אי התחשבות במתאם הסדרתי עלולה להביא למסקנות שגויות. מתאם סדרתי קיים, למשל, כאשר בוחנים שאריות ממודל רגרסיה שהותאם עבור נתונים של תהליך שתוצאותיו תלויות במשתנים מסבירים. דוגמא לכך הם נתוני מחקר על תאונות דרכים שחלק מההסבר לערכיהם מושג על ידי התאמת מודל רגרסיה שלוקח בחשבון שינויים בזמן (מגמה ועונתיות). כדי להעריך האם חל שינוי משמעותי בקצב התאונות יש לקחת בחשבון שינויים במסבירים ורק לבחון את החלק הלא מוסבר. שאריות הרגרסיה אינן בלתי תלויות.

לשלב שבו מורידים משתנים מסבירים כדי לבחון את השאריות מתייחסים כשלב של "עיבוד התחלתי" (Pre-processing). את השיטות לשלב זה ניתן לסווג לשיטות מסוג *model based*, או *data driven*. בשיטה הראשונה (*model based*) מקבלים את השאריות על ידי התאמת מודל בהתאם לאופי הנתונים, כמו למשל מודל של רגרסיה ליניארית עם היום בשבוע כמשתנה מסביר. לעומת זאת, בשיטה של *data driven*, מסירים מבנה מסוים בנתונים, למשל על ידי בחינת הפרשים במקום ערכי התהליך המקוריים. משתנה מסביר טיפוס המאפיין תהליכים המשתנים עם הזמן הוא היום בשבוע. שיטות החלקה שונות הוצעו להורדת מרכיב שונות זה: למשל, ממוצע נע של חלון של 7 ימים (Forsberg et al, 2006), או ניתוח סדרת הפרשים מסדר 7 (Muscatello, 2004). במספר עבודות הוצעו התמרות שונות של הנתונים שעבורם הנחת הנורמאליות מוצדקת, ומנתונים אלה מנכים את ההשפעה של היום בשבוע (Brillman et al, 2005; Burkorn et al, 2007). פירוט על שיטות שונות של שלב העיבוד ההתחלתי מובא במאמרים (Lotze et al (2008), Lotze and Shmueli (2008).

נושא כללי הקשור כמובן לנתוני מנייה הוא שיטות ניתוח נתונים עבורם הנחת הנורמאליות אינה מתאימה. בעבר, נהוג היה להשתמש בהתמרות של הנתונים המקוריים כך שעבור הנתונים המתמרים סבירה הנחת הנורמאליות. אולם, לאחרונה פותחו שיטות המאפשרות הסקה על בסיס ההתפלגות המתאימה לנתונים המקוריים. הבנת הממצאים על בסיס שיטות אלה קלה ופשוטה יותר עבור החוקרים המבקשים תשובה בסקלה המקורית של נתוניהם. דוגמא לכך תרשימי ה-CUSUM אשר פותחו על ידי (Brook and Evans (1972), Lucas (1985) ותרשימי ה-EWMA אשר פותחו על ידי (Borrer et al (1998) עבור תהליך פואסוני בעל תוחלת קבועה ותצפיות בלתי תלויות.

עבור התהליכים של משתני מנייה, בעשור האחרון, החלו ליישם מודלים של רגרסיה פואסונית כדי לנכות משתנים מסבירים ולהשתמש בשאריות לבחינת השינויים בתהליך (Brillman et al, 2005). לא תמיד מודלים כאלה מתאימים שכן הם מתבססים על הנחת סטציונריות, והנחה זו אינה תמיד מוצדקת. מגבלה זו צוינה בסקירה הרחבה המוצגת במאמרם של (Shmueli and Burkom 2010), שבו הם הציגו שיטות סטטיסטיות שונות וכן בעיות פתוחות בניטור נתונים שמטרתן לגלות התפרצות מחלות.

לעתים, התהליך הנחקר הוא אירועים ששיחותם נמוכה. במקרה זה, נהוג לעיתים למדל לא את תוצאות האירוע אלא את הזמן בין האירועים (לדוגמה, (Borrer et al, 2000).

חבילת התוכנה R כוללת תוכנה שפותחה לאחרונה על ידי (Hohle et al (2007) לניטור התפרצות מחלות מדבקות. תוכנה זו מתאימה לניטור נתוני מנייה, בהנחה שהנתונים מתפלגים פואסונית או שהם באים מהתפלגות בינומית שלילית, המתאימה לנתוני מנייה, עם שונות גדולה מהתוחלת. הנחיות לשימוש בתוכנה ודוגמאות ליישומה, מתוארים בדו"ח של (Wimmer and Hohle (2008). התוכנה מאפשרת להתאים מודל המניח שלוג התוחלת מוסבר על ידי מגמה ועונתיות. המגמה מבוססת כפונקציה ליניארית של זמן, והעונתיות על ידי פונקציות מחזוריות. החלק התיאורטי של שיטת ניתוח זו מתואר במאמר של (Hohle and Paul (2008). להלן עקרונותיה.

נסמן את התצפיות ב-  $\{x_t\}$ . צפיפות ההתפלגות ממנה התקבלו תצפיות אלה כאשר התהליך בבקרה, תסומן ב-  $f_{\theta_0}(. / z_t)$ , כאשר  $z_t$  הם משתנים מסבירים בזמן  $t$ . הצפיפות כאשר התהליך יוצא מהבקרה, תסומן ב-  $f_{\theta_1}(. / z_t)$ .

המודל מניח שבזמן שהתהליך בבקרה, לוג התוחלת מקיים:

$$\log(\mu_{0,t}) = \beta_0 + \beta_1 t + \sum_{s=1}^S [\beta_{2s} \cos(wst) + \beta_{2s+1} \sin(wst)]$$

$$w = \frac{2\pi}{T}$$

T הוא אורך המחזור של המרכיב העונתי, לדוגמה, עבור נתונים שבועיים, T=52.

מניחים שהשינוי בתהליך מתבטא על ידי:  $\log(\mu_1) = \log(\mu_0) + \kappa$ . מכאן:  $\mu_{1,t} = \mu_{0,t} \exp(\kappa)$ .

מעשית, כל הפרמטרים במודל אינם ידועים ונאמדים על בסיס אוסף נתונים בזמן שהתהליך בבקרה. כדי להעריך אם בנקודת זמן מסוימת, חל שינוי, מחשבים את הסטטיסטי (Lai, 1995):

GLR=Generalized Likelihood Ratio

$$GLR(n) = \max_{1 \leq k \leq n} \sup_{\theta \in \Theta} \left[ \sum_{t=k}^n \log \left\{ \frac{f_{\theta}(y_t)}{f_{\theta_0}(y_t)} \right\} \right]$$

כאשר ערכו של הסטטיסטי גדול מעל לערך קריטי שנקבע מראש, מסיקים על שינוי משמעותי.

## 6.2. בקרת איכות רב ממדית

לעתים קרובות נעשה מעקב על מספר משתנים סימולטנית. במעקב על תאונות דרכים, ראינו שהעניין הוא בבחינה סימולטנית של נפגעים בדרגות חומרה שונות ובסוגים שונים של דרכים. המשתנים שעליהם נעשה המעקב יכולים להיות תלויים או בלתי תלויים. הבעיה של מבחנים רבים ידועה בסטטיסטיקה. בכל מבחן סטטיסטי יכולה להיות טעות סטטיסטית (מסוג ראשון או שני), ולכן כאשר מבצעים מספר רב של מבחנים יש סיכוי גדול מאד שלפחות אחת המסקנות תהיה שגויה. שיטות סטטיסטיות מיוחדות פותחו במשך שנים רבות לטיפול במבחנים מרובים, וביניהן שיטות בבקרת



איכות. במהדורה האחרונה, השישית, של ספרו הקלסי של Montgomery על בקרת איכות, נכלל פרק על שיטות אלה.

השיטה הכי מקובלת בתחום זה מבוססת על חישוב של סטטיסטי הדומה מאד לסטטיסטי Hotelling  $T^2$  שהוא הרחבה למקרה הרב ממדי של הסטטיסטי  $t$ .  $T^2$  מוגדר באופן הבא: יהא  $\underline{X}_1, \dots, \underline{X}_m$  מדגם בגודל  $m$  מהתפלגות נורמלית רב ממדית. כל תצפית היא וקטור מממד  $p$ , של  $p$  משתנים מקריים. נסמן ב-  $\bar{\underline{X}}$  את הווקטור הממוצע של  $m$  הווקטורים, וב  $S$  את מטריצת השונות שלהם.

$$S = \frac{1}{(m-1)} \sum_{i=1}^m (\underline{X}_i - \bar{\underline{X}})(\underline{X}_i - \bar{\underline{X}})'$$

$$T^2 = (\underline{X} - \bar{\underline{X}})' S^{-1} (\underline{X} - \bar{\underline{X}})$$

הסטטיסטי הזה מתאר מרחק במרחב הרב ממדי, של תצפית מהממוצע. לא ניתן לדעת מפונקציה זו מה כיוון הסטייה מהממוצע, ומה הרכיבים שתורמים למרחק זה. בפועל, נוהגים להשתמש באמד הובסטי לממוצע וגם למטריצת השונות כדי שלתצפיות חריגות לא תהיה השפעה.

לכל תצפית מחשבים את המרחק במרחב הרב ממדי. התהליך ייחשב כתהליך במצב יציב כאשר לכל תצפית, המרחק שחושב הוא בגבולות הבקרה שהם:

$$UCL = \frac{p(m+1)(m-1)}{m^2 - mp} F_{\alpha, p, m-p}$$

$$LCL = 0$$

במאמרם של Tracy et al (1992) הם מראים שחישוב הגבול המבוסס על קירוב באמצעות התפלגות F עלול להיות לא מספיק מדויק, וממליצים במקום זאת

$$UCL = \frac{(m-1)^2}{m} \beta_{\alpha, p/2, (m-p-1)/2}$$

$$LCL = 0$$

$\beta_{\alpha, p/2, (m-p-1)/2}$  הוא אחוזון  $\alpha$  העליון של התפלגות בטא עם הפרמטרים  $p/2, (m-p-1)/2$ .

פותרו הרחבות של תרשימי הבקרה לנתונים רב ממדיים מסוג EWMA (MEWM) – ראה Lowry et al, 1992) וכן מהסוג CUSUM (MCUSUM), וכמו במקרה החד ממדי, מחקרים שונים שבוצעו להשוותם הראו שאין הבדל משמעותי בין הביצוע של תרשים רב-ממדי המבוסס על החלקה אקספוננציאלית, לבין זה המבוסס על סכומים מצטברים - ראה Fricker et al (2008).

### 6.3 שימוש בתרשימי בקרה למעקב בתאונות דרכים (סקר ספרות)

תרשימי הבקרה פותחו כאמצעי בקרת איכות בתהליכי ייצור. ההנחה הבסיסית בתרשימים אלה היא שבתהליך יציב אשר אינו מושפע ע"י גורמים מפריעים באופן שיטתי, כמות הפגמים במוצרי התהליך תישאר נמוכה - בגבולות של סטייה מקרית; במידה ומספר המוצרים הפגומים עולה (בתקופה מסוימת) בצורה משמעותית, תופעה זו אמורה להצביע על קיום גורם שיטתי מפריע אשר התערב בתהליך.

תפיסה זו קרובה להבנת תהליך התרחשות התאונות בשטח, כאירועים אקראיים, אך גם מושפעים על ידי גורמים מערכתיים רבים. לפיכך, כבר משנות ה-1960 נעשו ניסיונות ליישם תרשימי בקרה למטרות אופרטיביות של ניהול הבטיחות בדרכים. כך, למשל, Fisher and Mosher (1968) מציינים ששימוש בטכניקות ה-CC בניתוח תאונות הוצע ע"י חוקרים שונים עוד לפנייהם. החוקרים העירו

שתרשימי הבקרה מהווים כלים "טבעיים" לצרכי קבלת החלטות אופרטיביות, כאשר יש לזהות תופעות יציבות (stable patterns) בתוך המספר הרב של תנודות אקראיות בתאונות.

בעבודות אשר פורסמו בשנות ה-1960 הוצעו בעיקר כלים מתמטיים ליישום טכניקות ה-CC בתחום הבטיחות בדרכים (Fisher and Mosher, 1968; Fisher, 1970). השימוש בכלים אלה לא אומץ באותה תקופה, כפי הנראה עקב מחסור בבסיס מידע רלוונטיים וכן, בכלים ממוחשבים זמינים להפעלת כלים אלה. להערכת שינויים, בעשורים הבאים, אומצה הגישה של שימוש במודלים, בדומה לגישתנו בחלק הראשון אשר בעבודה זו. בשנות ה-1990, בעקבות המהפכה בתחום המחשבים וזמינות תוכנות סטטיסטיות, החלו ליישם את רעיון תרשימי הבקרה לצורכי ניהול הבטיחות.

סיבה אפשרית נוספת להפניית תשומת הלב לכלי הבקרה הינה שינוי התפיסה של בעיית הבטיחות בדרכים אשר התרחש בעשורים האחרונים, במדינות רבות. כיום, מקובל לבחון את בעיית הבטיחות בדרכים במדינה כבעיה מערכתית, עם כל מרכיבי הניתוח והניהול הנדרשים לכך. בין היתר, תוצרי המודלים הסטטיסטיים עם גבולות לחיזוי המצב, משמשים את צרכי הרשויות המפקחות להערכת ההתקדמות של התוכניות הלאומיות לבטיחות בדרכים. כלומר, אופן בחינת נתוני התאונות מתקרב לשיטת תרשימי הבקרה.

תוצאות חיפוש הפרסומים הרלוונטיים במאגר המידע הבינלאומי בנושאי התחבורה לא הראו עבודות רבות אשר דנו באופן ישיר ביישום תרשימי בקרה לצורכי ניהול הבטיחות. הפרסומים שדנו בשימוש בתרשימי הבקרה בתחום הבטיחות בדרכים, הוקדשו למטרות אלה:

- א. תמיכה בתהליכי קבלת ההחלטות, בנושאים כגון: הצבת משאבי אכיפה באזור (1968, Fisher and Mosher, 1970; Fisher, 1970); איתור מקומות תורפה (מהלאל, הקרט, 1976).
- ב. מעקב אחרי ביצוע התוכנית הלאומית לבטיחות בדרכים (Guria and Mara, 2000).
- ג. בחינת אמינות נתוני התאונות במאגר מידע לאומי (Pierchala and Surti, 1999).

במקרה הראשון, המחקרים הציגו את התאמת תרשימי בקרה ככלי בניתוח נתוני התאונות. הנתוח הבסיס לשימוש בנתוני התאונות לצרכי החלטות אופרטיביות הינן: (א) נתונים אלה משקפים את תהליכי היווצרות התאונות בשטח (accident causation process); (ב) השתנות מסוימת אופיינית לתהליך התרחשות התאונות בשטח, דהיינו גם ללא השינוי ברוב הגורמים המשפיעים (מצב התשתיות, הרכב, מזג האוויר וכו'), תיתכנה תנודות מסוימות במספרי התאונות שייצפו; אך במקרים מסוימים תנודות אלה מאותתות על שינוי מהותי בתהליך היווצרות התאונות, דהיינו מצביעות על מצב הדורש התערבות מצד הגורם המשגיח (כגון: תגבור אכיפה בקטע מסוים). ככל שמצב התאונות בתקופת המעקב נשאר קרוב ל"צפוי", יותר סביר להסיק על חוסר שינוי משמעותי בתהליך התרחשות התאונות בשטח; ולהפך, ככל שמצב התאונות בתקופת המעקב סוטה מה "צפוי", סביר להסיק על שינויים מהותיים בתהליך היווצרות התאונות.

תחת הנתוח אלה, וכן בהנחה שמספר התאונות בשטח מתפלג פואסונית (באתר ופרק זמן מסוים) (Fisher and Mosher (1968), Fisher (1970) הציגו נוסחאות לחישוב גבולות הבקרה בתרשימים, אשר נבנו על פי כללי ההחלטה המסורתיים:

כלל 1 - במידה ומספר התאונות הנצפה חוצה את הגבולות (שנקבעו לאתר ותקופת מעקב מסוימת) אזי מתקבלת מסקנה על שינוי מהותי בתהליך התרחשות התאונות;

כלל 2 - במידה ומספר התאונות הנצפה נשאר בתוך גבולות התרשים, המסקנה תהיה שהתהליך נשאר ללא שינוי.

מקובל מוגדרות: שגיאה מסוג 1 (the error of commission) ושגיאה מסוג 2 (the error of omission). ההסתברות לשגיאה מסוג ראשון,  $\alpha$  מבטאת את ההסתברות למסקנה מוטעית על קיום שינוי מהותי בתהליך כאשר שינוי זה לא התרחש בפועל. ההסתברות לשגיאה מסוג 2 ( $\beta$ ) מצביעה על הסיכוי לכישלון בזיהוי השינוי המהותי בתהליך. כידוע, לא קיימת אפשרות להקטין את שני סוגי השגיאות בבת אחת. ירידה בהסתברות של שגיאה מסוג אחד כרוכה בעליית ההסתברות לשגיאה

מסוג שני. Fisher and Mosher (1968) פיתחו גרפים המציגים את הקשר בין ערכי  $\alpha$ ,  $\beta$  ו-K (% שינוי בתוחלת התאונות הניתן לזיהוי באמצעות תרשים הבקרה) וסיפקו נוסחאות לחישוב אורך תקופת המעקב הנדרשת, בהתאם לפרמטרי הרגישות שנקבעו מראש (ערכי  $\alpha$ ,  $\beta$  ו-K) ובתלות במספר התאונות שנצפו בתקופת ה"לפני". כל הכלים הנ"ל פותחו ל-3 סוגים של תרשימי הבקרה: עם גבול עליון בלבד (לזיהוי הרעה במצב התאונות בלבד); עם גבול תחתון בלבד (לזיהוי שיפור בלבד); עם שני הגבולות (נועד לזיהוי של כל השינויים). לצורכי המעקב לאורך זמן, החוקרים המליצו על שימוש בסדרה של תרשימי הבקרה כאשר אורך תקופת המעקב, או גבולות התרשים בתקופה הבאה מתעדכנים בהתאם לניסיון התאונות בתקופה הקודמת.

בדוגמאות שהובאו ע"י Fisher and Mosher (1968), Fisher (1970), מתואר מעקב אחר התרחשות התאונות בקטעי דרך (קטעי סיור של המשטרה) כאשר תקופת המעקב נמדדו ביחידות של שבועות או חודשים. בדרך זו נבחנו כל סוגי התאונות הזמינים (סה"כ תאונות, מספר הרוגים, תאונות נזק בלבד, תאונות לילה וכו'). החוקרים הדגישו שממצאי המעקב באמצעות תרשימי הבקרה יכולים להצביע אך ורק על הצורך בבדיקה מעמיקה של נסיבות התאונות באתרי המעקב: התרשים נותן תשובה לשאלה "מתי" לחקור לעומק, אך אינו מסוגל להצביע על הסיבה האפשרית לשינוי.

Guria and Mara (2000) פיתחו כלים סטטיסטיים לשימוש תרשימי בקרה במסגרת מעקב אחרי ביצוע התוכנית לבטיחות בדרכים, ברמה ארצית/אזורית. כמדד המייצג את רמת הבטיחות בשטח נבחר סה"כ מספר ההרוגים במדינה/אזור. החוקרים הדגישו שימוש בתרשימי הבקרה בשני מצבים:

א - על מנת לזהות שינוי מהותי בהתרחשות התאונות בשטח;

ב - על מנת לקבוע, תוך זמן קצר, האם התוכנית מתבצעת בהתאם ליעדים הכמותיים (חסכון בהרוגים) שהוגדרו מראש.

בהתאם למצבים הנ"ל, גבולות של תרשים הבקרה נקבעים לפי מספר ההרוגים הצפוי (בתוספת מרווח הסמך הסטנדרטי) או לפי המקסימום של מספר ההרוגים שמוגדר מראש (כאשר המקסימום משמש לקביעת הגבול העליון של התרשים).

Guria and Mara (2000) דנו ביתרונות תרשים הבקרה לזיהוי שינוי מהותי במצב התאונות בשטח, בניגוד לשינוי אקראי. התרשים מאפשר שימוש יעיל במשאבים אופרטיביים (כגון: אכיפה משטרתית, מסעות פרסום) במהלך ביצוע תכניות (כגון: הצבה שונה של הכוחות או תגבור פעילות באתרים/אזורים מסוימים). כיחידות זמן בתרשימים נבחרו שבועות/חודשים. במחקרם, נמצא הבדל מובהק בין שיעורי ההרוגים בימי חול לעומת סופי שבוע. לאחר בדיקת המגמות בשיעורי ההרוגים בשני סוגי הימים, הוצעו נוסחאות להערכת השונות, וכן, לחיזוי מספר ההרוגים וגבולות הערך המסכם לשני סוגי הימים. נבחר ערך של 5% לשגיאה מסוג ראשון, כלומר התרשים כיסה טווח של 95% מהערך הצפוי. להערכת השונות שימשו נתוני ההרוגים מהתקופה של 10 שנים "לפני".

לצורכי תהליך המעקב - זיהוי מצבים חריגים, נקבעו כללי המעקב הבאים:

1. נקודה אחת (חודש או שבוע) הנמצאת מחוץ לגבולות התרשים.
2. חמש נקודות ברצף הנמצאות מצד אחד של קו המטרה (ציר האמצע של התרשים).
3. ארבע נקודות רצופות הנמצאות במגמת עלייה או ירידה.
4. שמונה נקודות רצופות הנמצאות בתוך האזור האמצעי (בגבולות של סטיית תקן אחת מהציר האמצעי).

כל אחד מהאירועים הנ"ל הוגדר כמצביע על קיום גורם מיוחד (special cause). למשל, כלל 4 מעיד על הקטנת השונות, מה שיכול להצביע על ירידה עקבית במספר ההרוגים. אשר לכלל 1, נקודה בודדת מעבר לגבול לעתים אינה דורשת נקיטת צעדים מיוחדים, פרט לבדיקת הנסיבות שגרמו לכך (כגון: תאונה אחת מרובת הרוגים). יחד עם זאת, חצייה חוזרת של הגבולות יש לפרש כהוכחה לשינוי רמת הסיכון בשטח.

כאשר שיעור ההרוגים השבועי נמוך, התרשים נוטה לרגישות גבוהה לשינויים בשבועות בודדים. לכן, Guria and Mara (2000) המליצו על שימוש בתרשים בקרה מצטבר (cumulative control chart) שבו קו המטרה (האמצעי) מהווה סיכום מצטבר של הערכים הצפויים (על בסיס שבועי). במחקרם של Guria & Mara (2000), הם בנו תרשימים מסוג Shewhart וכן תרשימי CUSUM לניטור מספר הנפגעים השבועי בתאונות הדרכים בני-זילנד. בסיס הנתונים התייחס לשנים 1987-1996. מסקנתם הייתה שהתרשים מסוג CUSUM הראה תמונה יותר ברורה לעומת תרשימי Shewhart, ומסקנתם על בסיס תרשים ה-CUSUM הייתה שמגמת השינוי בזמן הייתה של שיפור והתקרבות לערך היעד אשר הוצב להורדת מספר הנפגעים. במאמר מאוחר יותר (Guria et al (2003), החוקרים השתמשו בתרשימי ה-CUSUM כדי להעריך את השפעתם של מספר שינויים בדרכי האכיפה ובתקנות אשר נעשו בניו-זילנד על תאונות שסיבתן נהיגה תחת השפעת אלכוהול. החוקרים השתמשו ב-V-mask כאמצעי עזר להבנת התרשימים שהתקבלו ולהערכת מובהקות השינויים שהתרשימים הראו. מסקנתם על בסיס הממצאים הייתה שהפעלת שני האמצעים שנועדו להפחית את מספר התאונות כתוצאה מנהיגה תחת השפעת אלכוהול אכן הביאה לירידה מובהקת. אולם, לשינוי בחוק שהוריד את גבול גיל השתייה המותר מ-20 ל-18 הייתה השפעה שלילית של גידול מובהק במספר התאונות כתוצאה מנהיגה תחת השפעת אלכוהול בקבוצת הגיל של הצעירים בני 14-17.

Pierchala and Surti (1999) דיווחו על הקמת מערכת לביצוע מעקב אחרי איכות הנתונים המתקבלים בשני בסיסי הנתונים בארה"ב: FARS - בסיס נתונים מקיף לדיווח על הרוגים בתאונות בדרכים; GES - בסיס נתונים המייצג את כלל התאונות הנרשמות ע"י המשטרה בארה"ב (באמצעות דגימת התאונות מאזורים מסוימים). המעקב מבוצע במאגר הנתונים המרכזי, באחריות הרשות הלאומית לבטיחות בדרכים (NHTSA).

מבחינת מרכיבי השיטה, נעשה שימוש ישיר בתרשימים מסוג *p-chart* המתוארים בספר הדרכה לבקרה איכות של Western Electric, משנת 1956. התרשים בנוי עבור אחוז ערכים מסוימים בשדה מסוים (כגון: אי-שימוש בחגורות בטיחות ע"י נוסעי רכב), על בסיס חודשי. מכאן, בעבודה השוטפת נבנים עשרות תרשימים לסוגי מאפיינים ואזורי אספקה שונים. שנתיים קודמות משמשות לחיזוי המצב בשנת המעקב. גבולות התרשים מחושבים ברובם של שלוש סטיות תקן מהקו המרכזי.

לזיהוי מצבים חריגים בהקשר הנ"ל הוגדרו כללי המעקב הבאים:

כלל 1 - נקודה אחת בחוץ לגבולות התרשים;

כלל 2 - שתי נקודות מתוך שלוש נקודות רצופות נמצאות במרחק יותר משתי סטיות תקן מהקו המרכזי;

כלל 3 - ארבע מתוך חמש נקודות רצופות נמצאות במרחק יותר מסטיית תקן אחת מהקו האמצעי (בצדו האחד של הקו);

כלל 4 - שמונה נקודות רצופות נמצאות מצדו האחד של הקו האמצעי.

בכל אחד מהמצבים הנ"ל התהליך מתפרש ככזה ש"יצא מכלל השליטה" (out-of-control). נראה כי במערכת זו האירועים החריגים המזוהים באמצעות תרשימי הבקרה יכולים להוות שילוב של שתי קבוצות גורמים: מחד, התופעות השונות של אי-יציבות בתהליכי דיווח על התאונות, ומאידך, שינויים ארוכי טווח במצב גורמי הבטיחות בשטח.

ניתן לראות שחלק מכללי הבקרה הנ"ל מזכירים את הכללים שתיארנו מתוך מחקרם של Guria and Mara (2000).

לסיכום, במדינות רבות בעולם מבוצעים מעקב ובקרה שוטפים אחרי המגמות בתאונות הדרכים. למגמות אלה חשיבות במיוחד כאשר מוצבים יעדים לאומיים בבטיחות בדרכים, במונחים של הפחתה במספרי ההרוגים ו/או התאונות. למעקב אחרי מגמות ההשתנות בהרוגים והתאונות משמשות לרוב שיטות ויזואליות.

תרשימי הבקרה יכולים להוות כלי שימושי לצורכי המעקב אחרי התפתחות מצב הבטיחות במדינה, כאשר המטרה העיקרית הינה לאפשר לגורם המפקח להבדיל בין הסטייה האקראית במספר התאונות (הנפגעים/ ההרוגים) לבין ההתפתחות המצביעה על שינוי מהותי בגורמי התאונות. שינוי מהותי זה יחייב קבלת החלטות אופרטיביות על מנת לנקוט בצעדים ואמצעים לתיקון השינוי שהתרחש בשטח (כגון: תגבור אכיפה באזורים מסוימים, ביצוע מסע הסברה וכו').

לתרשימי הבקרה כשיטת המעקב מייחסים את התכונות הבאות:

- תרשים הבקרה מהווה כלי לזיהוי מהיר של השינוי המהותי אך אינו מספק תשובה לסיבות השינוי. לבחינת סיבות השינוי נדרשת חקירת המצב לעומק;
- ליצירת תרשים בקרה או, במובן כללי יותר, לבניית התחזית להתפתחות המצב בתקופה מסוימת, משמשים נתוני התאונות מהתקופה "לפני";
- המעקב ניתן לביצוע על בסיס חודשי או שבועי. הבחירה מתבססת על סדרי הגודל של הנתונים הנבחרים, קצב העדכון המקובל, צורכי המעקב - פרקי זמן רצויים בקבלת ההחלטות וכד';
- גבולות התרשים נקבעים בהתאם לרמת הדיוק הרצויה במעקב. מקובל לקבוע הסתברות לשגיאה מסוג ראשון ברמה של 5%;
- במהלך יישום של תרשימי הבקרה, מתגבשים כללים אמפיריים לזיהוי מוקדם של התופעות החריגות בהתפתחות התהליך (ומכאן, לקביעת הצורך בהתערבות).

#### 6.4. יישום השיטות הסטטיסטיות של תרשימי בקרה במחקר זה

למודל של Hohle שתואר בתחילתו של החלק השני יש יתרון בכך שתרשימי הבקרה מתארים את המעקב על ידי הצגת הנתונים בסקלה המקורית. אולם בשיטה זו גם חסרונות, בפרט הבנת התרשימים הנוצרים בשיטה זו דורשת יותר מיומנות כי לכל תצפית אין בהכרח אותה שונות. לעומת זאת, מוכר וקל יותר להבין את תרשימים הקלסיים כאשר הם נבנים על בסיס השאריות, שהן בלתי תלויות ושונות בשונותיהם (בפרט מהסוג של Shewhart, אך גם התרשימים מסוג: EWMA, CUSUM). כדי שיהיה מוצדק להשתמש בשאריות אלה, יש לדאוג לכך שכאשר התהליך בבקרה והמודל המותאם לו נכון, השאריות תהיינה ככל האפשר בעלות התפלגות נורמלית, עם תוחלת אפס ושונות קבועה.

במחקרנו, השתמשנו בגישה של ניטור השאריות בעזרת תרשימי הבקרה. השאריות התקבלו לאחר "עיבוד התחלתי" בשיטה של "model based". לכל סידרה הותאם מודל (פואסוני או בינומי שלילי), מהמודל נוכה החלק שניתן להסבר על ידי המודל ולאחר שלב זה, השאריות נבחנו בעזרת הכלים הסטנדרטיים של SPC - דהיינו, תרשימים מסוג Shewhart ו-Cusum, ו-Ewma. נבדקו השאריות כדי לוודא שהתפלגותן בקירוב נורמלית, עם תוחלת אפס ושונות קבועה.

Rossi et al (1999) מציעים במאמרם שלוש טרנספורמציות האמורות להמיר נתונים פואסוניים לנתונים נורמליים סטנדרטיים, אשר עבורם ניתן להשתמש בשיטות SPC הסטנדרטיות.

אם  $X_t$  - הנתון המקורי ו-  $\mu_t$  הוא תוחלתו אזי ההתמרות המוצעות הן:

$$Z1_t = \frac{X_t - \mu_t}{\sqrt{\mu_t}}$$

$$Z2_t = 2(\sqrt{X_t} - \sqrt{\mu_t})$$

$$Z3_t = \frac{X_t - 3\mu_t + 2\sqrt{\mu_t}X_t}{2\sqrt{\mu_t}}$$

ההבדלים בין ההתמרות אמורים להתגלות עבור ערכי  $\mu_t$  נמוכים. מכיוון ש- $\mu_t$  אינו ידוע משתמשים באמד ל- $\mu_t$ . טרנספורמציות אלה מגדירות למעשה שלושה סוגי שאריות עבור הנתונים.

אין במאמר הצעות לגבי נתונים הלקוחים מהתפלגות בינומית שלילית.

אנו לא השתמשנו בשיטה זו, אלא בשאריות מהמודל מהסוג: שאריות דיוויאנס. הן כידוע, מפולגות בקירוב נורמלית, עם שונות קבועה, כאשר האמד ל- $\mu_t$ , כלומר המודל, נכון. היתרון בשימוש בשאריות אלה הוא חישובי. שאריות אלו מוגדרות באופן פשוט לחישוב הן עבור ההתפלגות הפואסונית והן עבור ההתפלגות הבינומית שלילית. (דיון והשוואת תכונות של סוגי שאריות עבור Generalized Linear Models ניתן למצוא ב-Pierce & Schafer, 1986). השוואת סוגי השאריות עבור הנתונים של הסדרות במחקר זה הראתה שהקורלציה ביניהן קרובה מאוד ל-1, כפי שצפוי מכיוון שהערכים של הסדרות גבוהים. לכן, השתמשנו בשאריות הדיוויאנס.

בבקרת איכות סטטיסטית מבחינים בשני שלבים. השלב הראשון, הנקרא גם Phase I, הוא שלב ה-"setup". השלב השני, Phase II, הוא שלב הניטור – "monitoring". בשלב הראשון משתמשים בנתונים רטרוספקטיביים, ביישום זה הכוונה לנתוני ה"לפני", כדי לקבוע את הפרמטרים של תרשים הבקרה. פרמטרים אלה משמשים לניטור התהליך בשלב השני (ביישום זה הוא התקופה "אחרי").

## **7. בדיקת מגמות בתאונות הדרכים החמורות, בשנים האחרונות, בעזרת תרשימי בקרה**

### **7.1. כללי**

בחלק זה ניישם את ממצאי ניתוח סדרות הנתונים בעזרת תרשימי בקרה. נדגים את יישומם הן על 3 סדרות מתוך הסדרות שבידינו וכן על סדרות סינטטיות, כאשר המטרה היא להסיק על רגישות התרשימים לשינויים בנתונים.

על פי תוצאות ניתוח הסדרות אותן נתחנו בחלק זה, בחינת התפלגותן ושאריותיהן, הסקנו שההתפלגות המתאימה לתיאור סדרות אלה הינה ההתפלגות פואסונית. לא התגלו סימני תלות בין השאריות, לאחר ניכוי רכיבי המגמה, העונתיות והמלחמות.

נציג תרשימים מסוג Shewhart ו-Cusum, וכן EWMA. כן ננסה לבחון האם יש יתרון כלשהוא בבחינה באמצעות תרשימי Shewhart ו-Cusum רב ממדיים.

### **7.2. הצגת הסדרות שתנתחנה**

נפרט תחילה מה הסדרות שתבחנה. אורך כל סדרה היה 72 תצפיות חודשיות. בכל סדרה, כללנו כתקופה "לפני", דהיינו שלב ראשון של בניית התרשים, את 60 החודשים הראשונים בסדרה. התקופה "אחרי" אליה התייחסנו כשלב שני כללה את החודשים 61-72.

#### **הסדרות המקוריות**

הסדרות המקוריות שנתחו הן:

S1-Total-fatalities

S2-Fatalities-rural roads

S3-Fatalities-urban roads

s1 הוא סכום של s2 ו-s3. לשלוש הסדרות האלה התאימה התפלגות פואסונית.

## הסדרות המלאכותיות

בבחינת ביצועי תרשימי הבקרה על סדרות הנתונים, כאשר תרשים מצביע על שינוי בתהליך, אין אנו יכולים לדעת האם אכן היה שינוי. מצד שני, אם התרשימים לא מגלים שינוי, איננו יכולים לדעת האם אכן לא חל שינוי בתהליך. על מנת לבדוק את ביצועי תרשימי הבקרה על סדרות הקרובות ככל האפשר לסדרות הנתונים, יצרנו בעזרת סימולציה סדרות מלאכותיות.

יצרנו סדרות s3000, s3005, s3010 ו-s3015 באופן הבא. השתמשנו במודל התאורטי של הסדרה s3 כדי לייצר את סדרות הנתונים, כאשר הנתון עבור תצפית מוגרל מהתפלגות פואסונית. עבור התצפיות עד לתצפית 64, נבחרה לכל תצפית, תוחלת השווה לאמד התוחלת על פי המודל של התצפית. עבור התצפיות בסדרה s3005, לאחר תצפית 64 הוכפלה כל תצפית, ב-1.05 בערך (כך שיצא מספר שלם), ובאופן אנלוגי, ב-1.1 ו-1.15 בהתאמה, לסדרות, s3010 ו-s3015. כלומר, יצרנו סדרות עם שינוי של גידול ב-5%, 10% ו-15%, בהתאמה, לאחר התצפית ה-64.

## 7.3 תרשימי Shewhart, Cusum ו EWMA חד-ממדיים של הסדרות

### 7.3.1 הקדמה

שורטטו ארבעה תרשימי בקרה עבור כל סדרה. שני התרשימים הראשונים הם תרשימי Shewhart. התרשים הראשון התקבל על ידי פרוצדורת Shewhart של SAS/QC, והשני על ידי פונקציית qcc של ספריית qcc מתוכנת R (Scrucca, 2004). שני התרשימים זהים, פרט לסימונים של "סיבות מיוחדות", לכן הצגנו את שניהם. פרט לגילוי נקודות החורגות מגבולות הבקרה, מצביע התרשים מתוכנת R על "violating.runs" - על פי הכלל של K נקודות או יותר ברצף מצדו האחד של קו האמצע (ממוצע התהליך). ברירת המחל, אותה השארנו, היא  $K=7$ . אין בתרשים מסוג זה התייחסות למקרה של רצף של נקודות שעולות או יורדות מנוטונית, או כללים אחרים של "סיבות מיוחדות".

התרשים השלישי עבור כל סדרה הינו תרשים מסוג CUSUM והרביעי מסוג EWMA. שני התרשימים האחרונים בוצעו גם הם באמצעות פונקציות cusum ו-ewma, בהתאמה של ספריית qcc מתוכנת R (Scrucca, 2004).

### 7.3.2 תרשים Cusum

במחקר זה יושמו תרשימי CUSUM חד צדדיים (one-sided cusum). תרשים CUSUM חד צדדי נועד לגלות סטייה קבועה במוצע התהליך המבוקר בכיוון מסוים, כלפי מעלה או מטה. בתרשימי ה-CUSUM המובאים במסמך זה, צוירו שני תרשימי CUSUM חד צדדיים על אותו גרף. תרשים אחד, בעל ערכים אי-שליליים נועד לגלות סטייה כלפי מעלה, ואילו התרשים השני, בעל ערכים אי-חיוביים נועד לגלות סטייה כלפי מטה. תרשים זה ברור יותר להבנה מתרשים CUSUM דו צדדי, אשר נועד לגלות חריגה בכיוון כלשהוא. כאשר נקודות התרשים חורגות מגבולות הבקרה מוכרז על שינוי מובהק בתהליך - יציאה מבקרה.

בנוסף ניתן באמצעות התרשים לאתר בקלות הזזות במוצע התהליך, מכיוון שהזזות כאלה גורמות לשינוי בשיפוע הנקודות של התרשים. הנקודה בה משתנה השיפוע היא הנקודה שאליה מתייחסים כנקודה שבה חלה ההזזה.

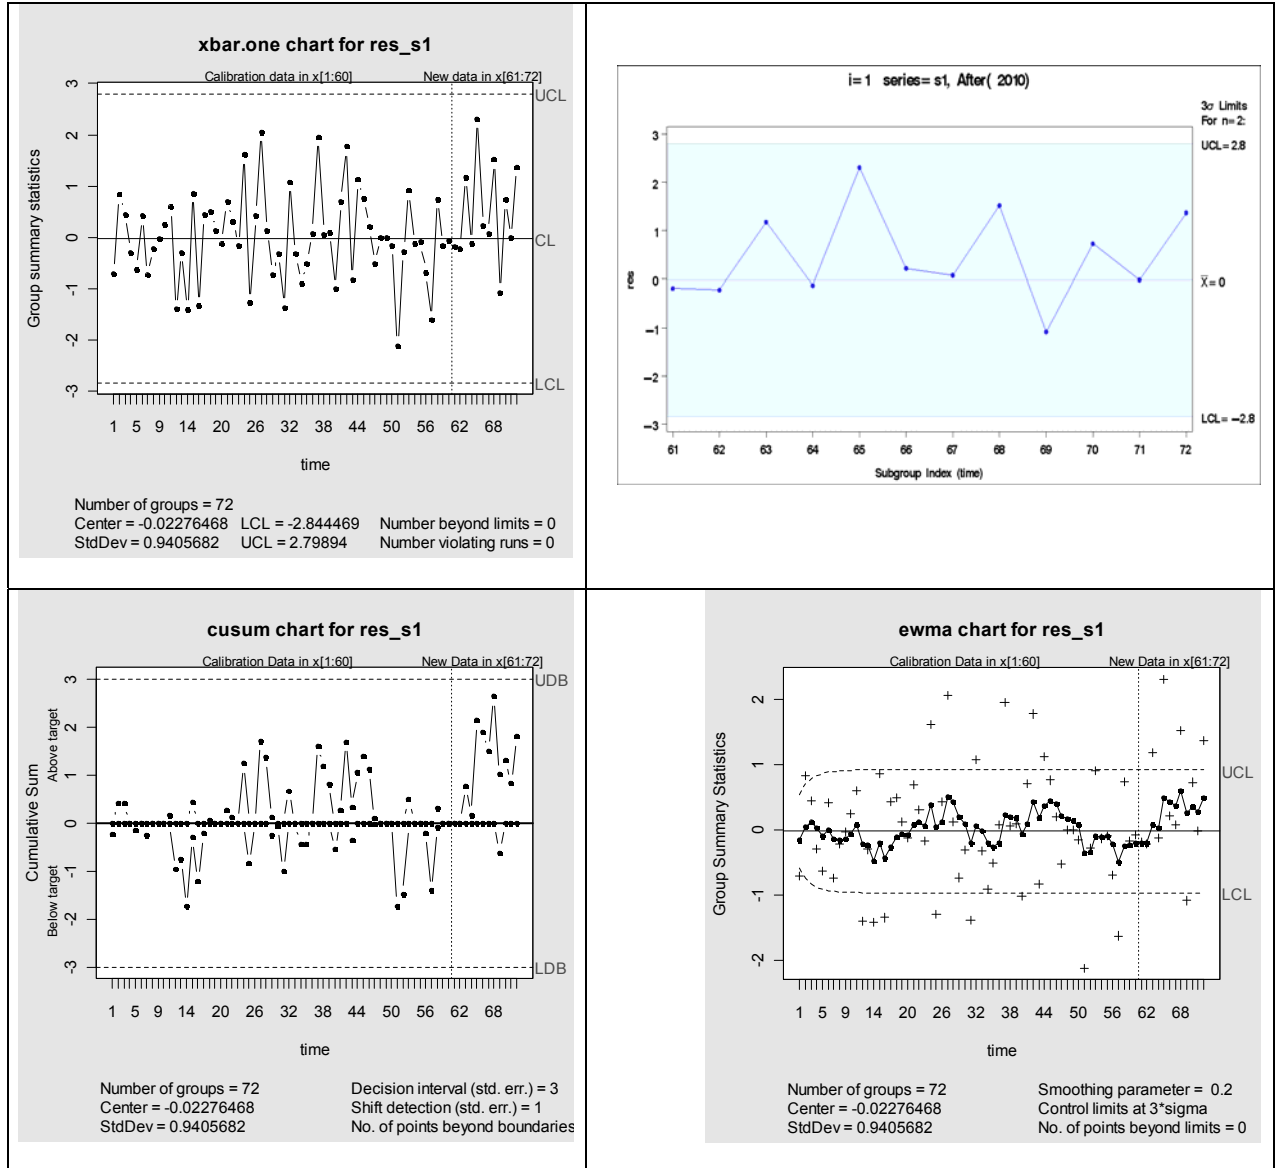
### 7.3.3 תרשים ה-EWMA

תרשים ה-EWMA מחליק סדרה של נתונים, על ידי שימוש במוצע נע משוקלל, עם משקולות אשר דועכים אקספוננציאלית. הוא מקובל ככלי שימושי לגילוי סטייה קטנה, אך קבועה (לא חד פעמית) במוצע של התהליך המבוקר.

## 7.3.4 התרשימים שנבנו והמסקנות

### סדרה מקורית S1

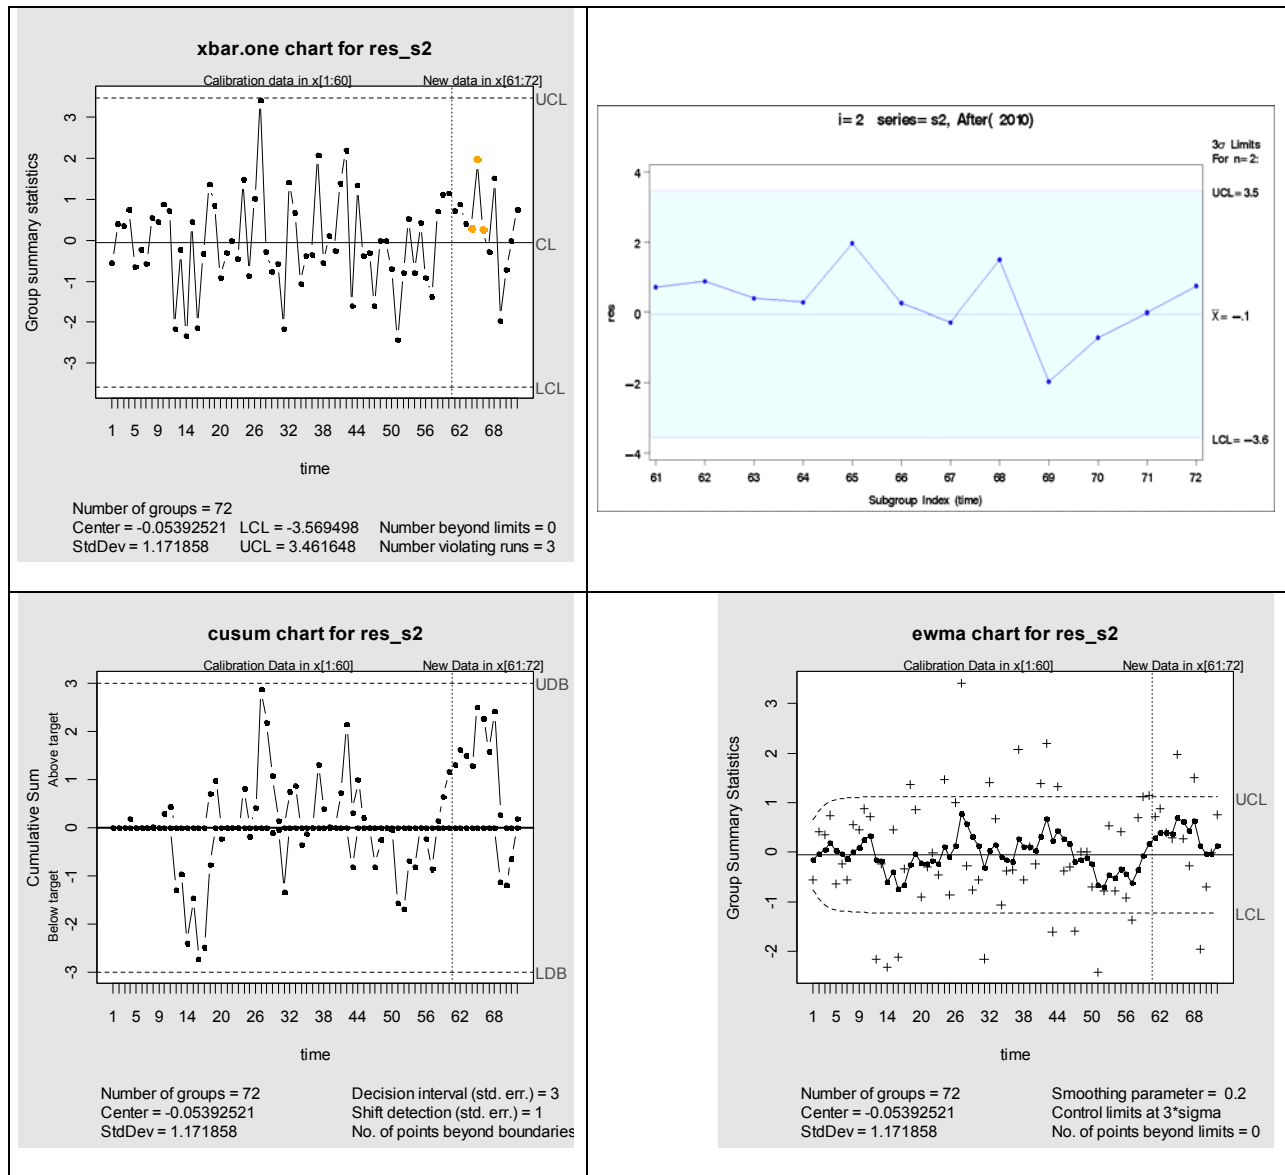
מסקנות מהתרשימים עבור סדרה זו, הן שהתהליך נראה בבקרה.



### סדרה מקורית S2

בתרשים הראשון עבור סדרה זו, נראה שבתקופה "אחרי" יתכן שהיה שינוי אפשרי, מאחר שרואים רצף נקודות מעל לממוצע הצפוי. אולם לא כך ניתן להסיק מהתרשימים הבאים אחריו.

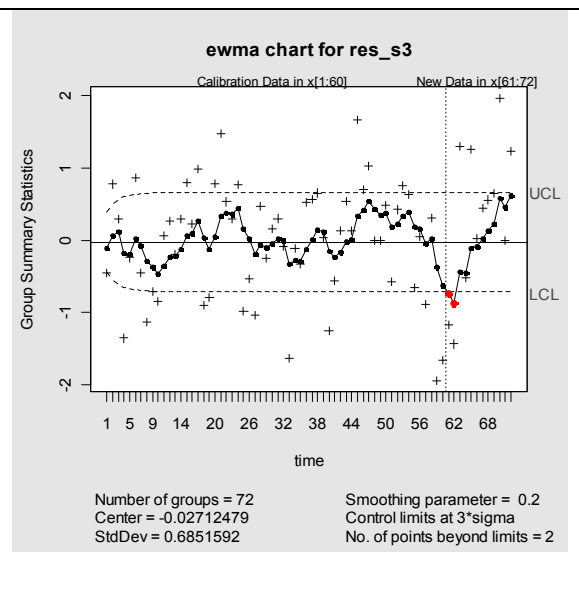
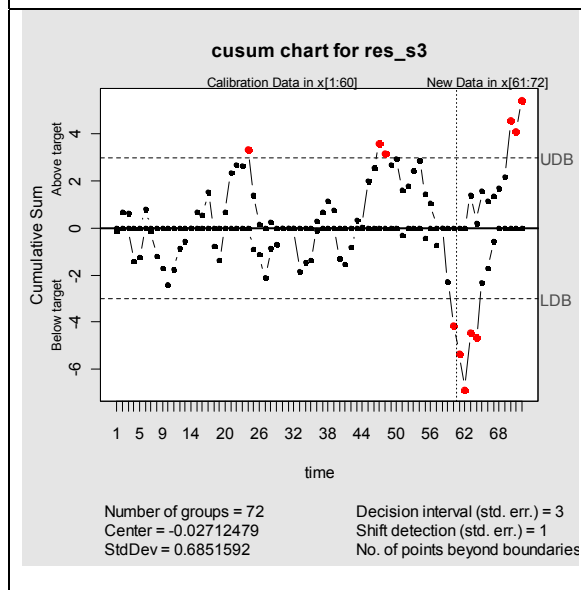






### סדרה מקורית S3

עבור סדרה 3 נראה שהתהליך לא היה בבקרה מלאה, בחלק ש"לפני" וגם "אחרי".

השוואה בין הממצאים בכל 4 התרשימים מדגימה את הרגישות השונה שבכל סוג ובהתאם לכך את המסקנות שניתן לקבל מכל תרשים. לעתים, כמצופה, אין המסקנות זהות. לתרשים המופק ב-SAS יש יתרון בקלות הסקת המסקנות ממנו בגלל ציון אופי הסטייה. לא נראה שיש יתרון בתרשים מסוג EWMA כאשר בוחנים אותו בתוספת לשאר התרשימים. אולם, בדוגמה זו, ניתן לראות את היתרון בתוספת של תרשים מסוג CUSUM. התרשים מציג בצורה בולטת את השינויים הגדולים יחסית בסוף תקופת ה"לפני" שהחלו בירידה מלווה בעלייה בתקופה ש"אחרי".



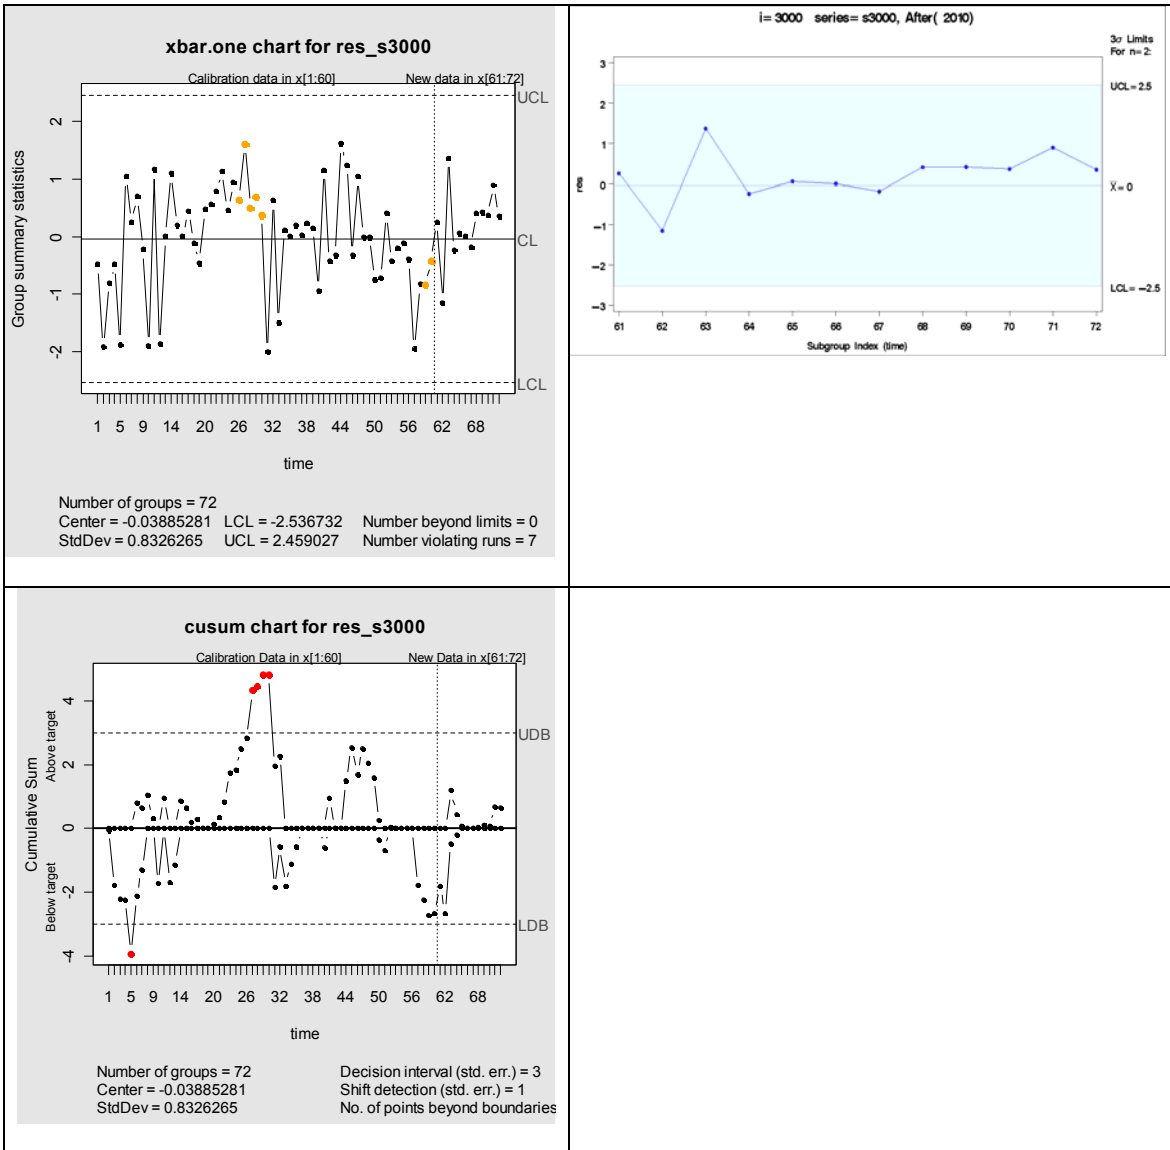
בהמשך הדו"ח, כדי להקל בקריאה לא נציג את התרשימים מהסוג EWMA. באף אחד מהמקרים שניתחנו לא הייתה שום תוספת משמעותית למידע מתרשימים אלה, מעבר למה שניתן היה להסיק מהתרשימים מסוג אחר.

### סדרות מלאכותיות

התרשימים הבאים מתייחסים לסדרות המלאכותיות שיצרנו ועבורן נבנו תרשימי בקרה.


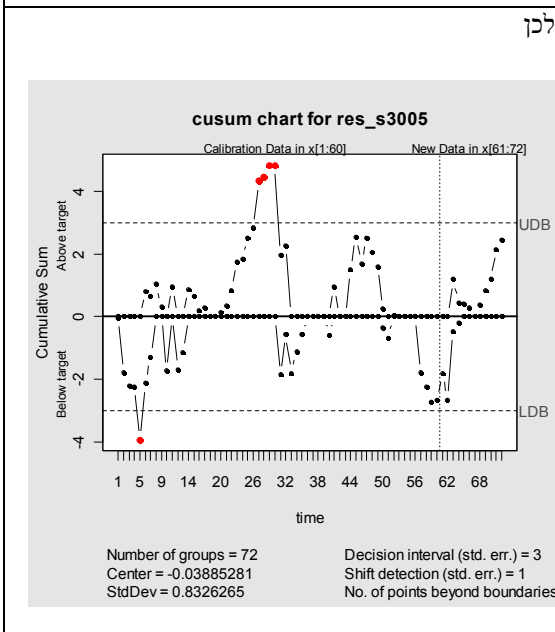

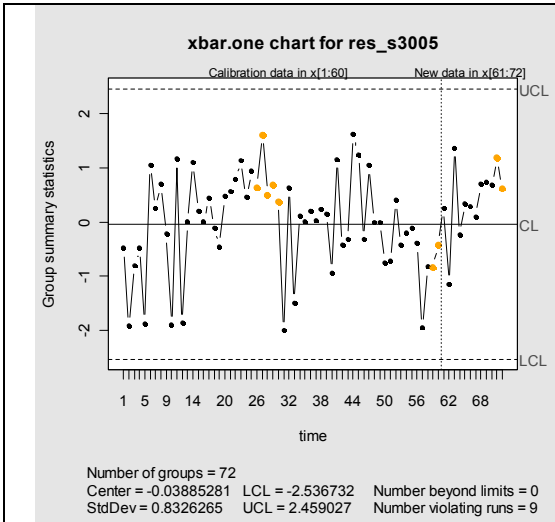
נציג כאן את הממצאים עבור הסדרה הראשונה שבה כל התהליך אמור להיות תהליך בבקרה, הן "לפני" והן "אחרי". לאחר מכן, נציג את התרשימים לסדרה שבה בתקופה "אחרי" היה שינוי קטן יחסית של עליה ב 5% בתוחלת ובהמשך, את התרשימים לסדרה שבה בתקופה "אחרי" היה שינוי יותר גדול של עליה ב 15% בתוחלת.

בסדרה הראשונה הנתונים נוצרו כמייצגים תהליך בבקרה. לכל תצפית שהוגרלה מהתפלגות פואסונית עם תוחלת ידועה, הותאם המודל הנכון והתרשים נבנה על בסיס השאריות של מודל נכון זה. למרות זאת, התרשים הבא וגם התרשים CUSUM מצביעים על אפשרות שהתהליך אינו יציב בתקופה אשר "לפני". זו דוגמה למקרה של "false alarm".



התרשימים הבאים המתאימים לסדרה שיצרנו עם שינוי קטן יחסית של עליה ב-5% בתוחלת.

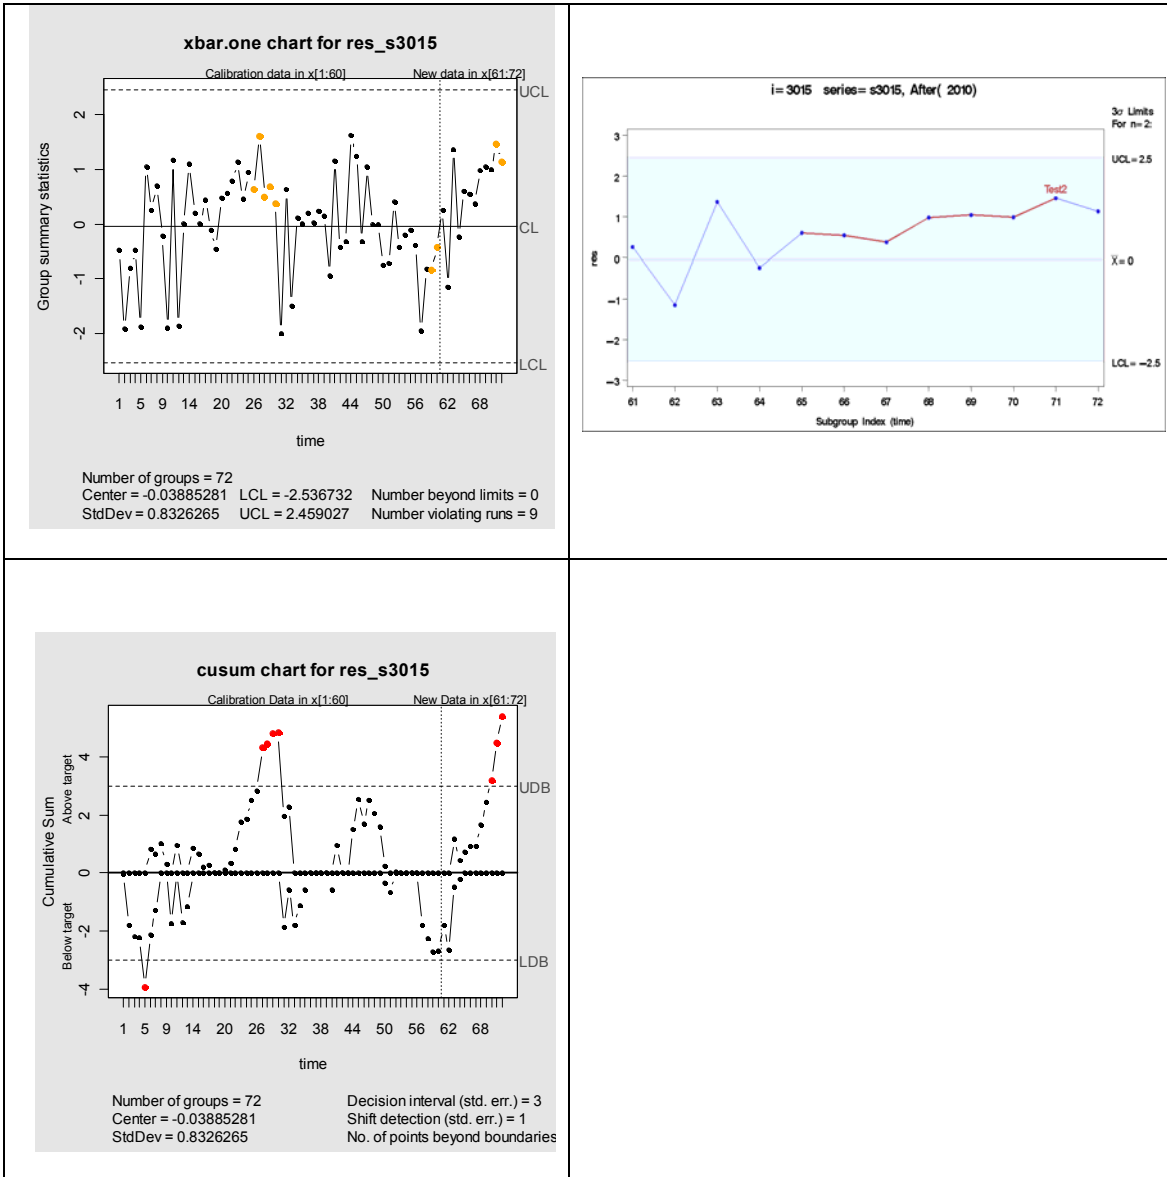
כפי שניתן לראות, שינוי קטן יחסית כזה כבר מתבטא בממצאים המתקבלים מתרשימי הבקרה מסוג Shewhart.



התרשימים הבאים המתאימים לסדרה שיצרנו עם שינוי של עליה ב-15%.

בתרשימים מסוג Shewhart לא רואים הבדל בין התרשים המתאים שהתקבל לסדרה זו (על עליה של 15%) לעומת התרשים הקודם עם השינוי הקטן יותר של 5%.

לעומת זאת, בתרשים מהסוג CUSUM, רואים בניגוד לעליה הקטנה יחסית, שהשינוי מתבטא בתרשים המראה על העלייה בתוחלת.



בסיכום, מסקנתנו היא שיש יתרון רב בשימוש בתרשימי הבקרה על בסיס השאריות ככלי מעקב על הנפגעים בתאונות הדרכים. כמו כן, הראינו את היתרון בבחינה סימולטנית של שני סוגי התרשימים: Shewhart ו- CUSUM.

## 7.4. תרשימי Shewhart, Cusum ו-EWMA רב-ממדיים

כאשר יש לבקר מספר משתנים בו זמנית ניתן לעתים ללמוד מניתוח נוסף רב ממדי כתוספת לניתוח הנפרד לכל סדרה. ניתן לעתים לזהות בעיות שאינן מזוהות בניתוח של כל סדרה בנפרד. בסעיף זה נציג ניתוח דו-ממדי של הסדרות s2 ו-s3, בהשוואה לניתוחים חד-ממדיים של סדרות אלה, ושל סדרות מלאכותיות הנגזרות מסדרות אלה. בנוסף נשווה את מסקנותינו מהניתוחים הדו-ממדיים לניתוח הסדרה s1 אשר שווה לסכום של s2 ו-s3. ניתוח סכום של סדרות, מוכר כאמצעי לניתוח סדרות רב-ממדיות פואסוניות, כמו לדוגמה ב-Kuo and Lin (2009).

## **7.4.1. הצגת הסדרות שתנותחנה**

### **סדרות מקוריות**

הסדרות המקוריות שמנותחות הן:

s2-Fatalities-rural roads

s3-Fatalities-urban roads

וכן, s1 (Total-fatalities) אשר הוא כאמור סכום של s2 ו-s3. נדון בהבדל בין ניתוח s2 ו-s3 כשתי סדרות בו זמנית לעומת ניתוח סכומן.

### **סדרות מלאכותיות**

יוצרו סדרות s1000, s1005, s1015 באופן הבא. השתמשנו במודל התאורטי של הסדרה s1 ליצר את סדרת הנתונים, כאשר הנתון עבור תצפית מוגרל מהתפלגות פואסונית עם תוחלת השווה לאמד התוחלת על פי המודל של אותה תצפית. עבור התצפיות לאחר תצפית 64 הוגדלו מספר התאונות ב-5% בקרוב בסדרה s1005, וב-30% בקרוב בסדרה s1030. הסדרה s1000 מובאת לצורך הצגת הנתונים שהוגרלו מהתהליך המקורי, ולהשוואת התרשימים בין סדרה הנמצאת בבקרה לסדרות שלא בבקרה. השתמשנו גם בגידול של 30% מפני שגידול באחוזים נמוכים יותר לעיתים לא נתן הבדל בין ערכי הסדרות - בשל הצורך שהערכים המוגדלים יהיו שלמים.

מכיוון שהסדרה s3 היא סכום של הסדרות s2 ו-s3, חושבה s2 כהפרש בין s1 ו-s3. באותו אופן חושבו כל הסדרות הנגזרות מ-s2.

## **7.4.2. תרשים ה-Shewhart הרב-מימדי**

התרשים נוצר על ידי פונקציית  $mqcc$  מתוך סיפריית qcc של R (Scrucca, 2004). תרשים זה מבצע את "Hotelling  $T^2$  chart for individual observations", אשר כפי שצינו מחושב עם אמד רובסטי עבור מטריצת הקובריאנס.

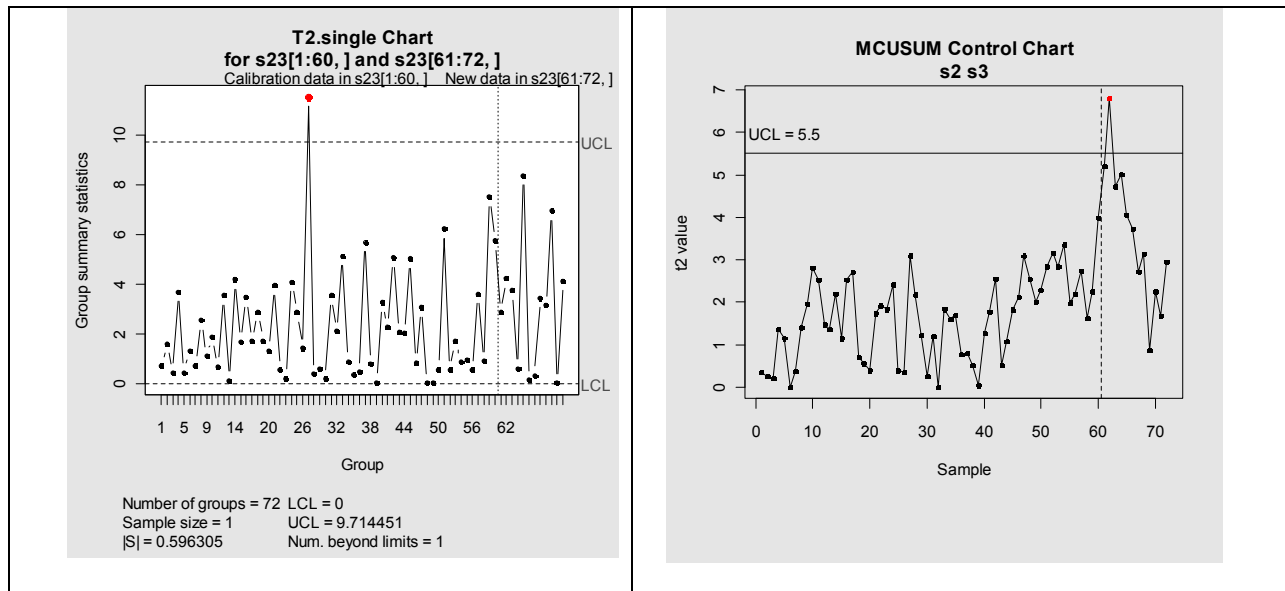
## **7.4.3. תרשים ה-MCUSUM**

התרשים נוצר על-ידי פונקציית  $mcusum$  מתוך סיפריית MCUSUM של R (Edgar, 2011). השיטה מוצגת ב-Crosier (1988). היישום ב-R בנוי להשיג ARL של 200.

## **7.4.4. התרשימים שנבנו**

### **s3,s2 מקוריים מנותחים סימולטנית**

כזכור, כשנותחה כל אחת מהסדרות לחוד ראינו שעבור הסדרה s3 היו נקודות מחוץ לגבולות הבקרה. לכן, לא מפתיע שגם בתרשים הרב-מימדי התקבל ממצא של נקודה חריגה. הנקודה בתרשים זה מתאימה לאותה תצפית שסומנה בתרשים ה-CUSUM לסדרה זו.

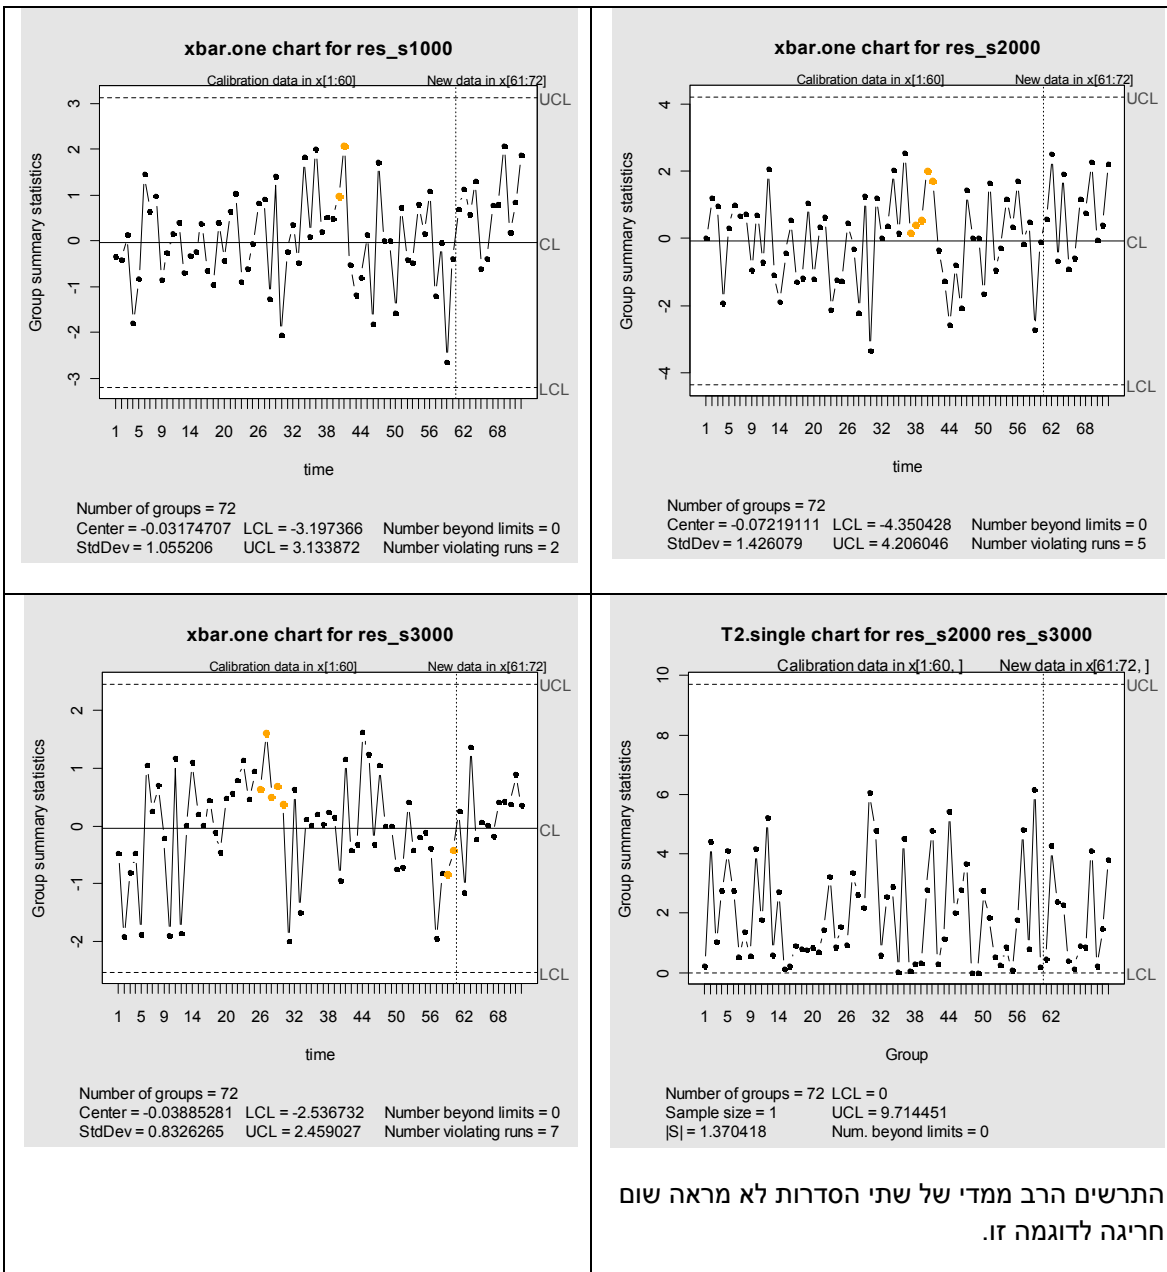


בתרשים מסוג MCUSUM רואים שינוי חד בתצפית הראשונה שבתקופה "אחרי", וזהו ממצא שונה ממה שראינו בניתוח הנפרד.

### תרשימים לסדרות המלאכותיות

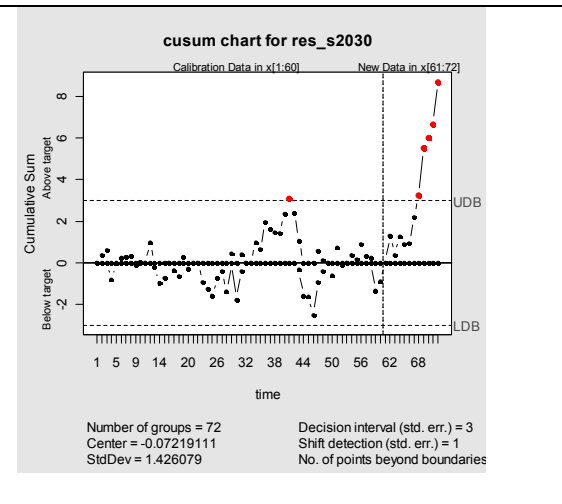
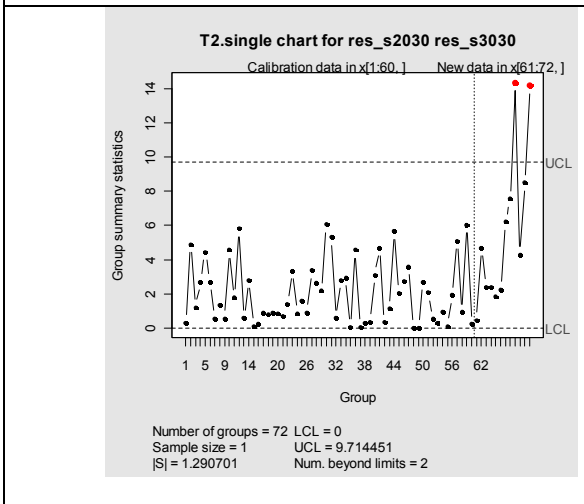
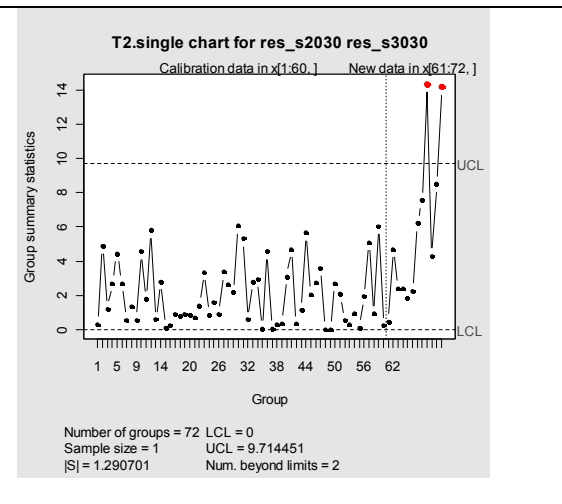
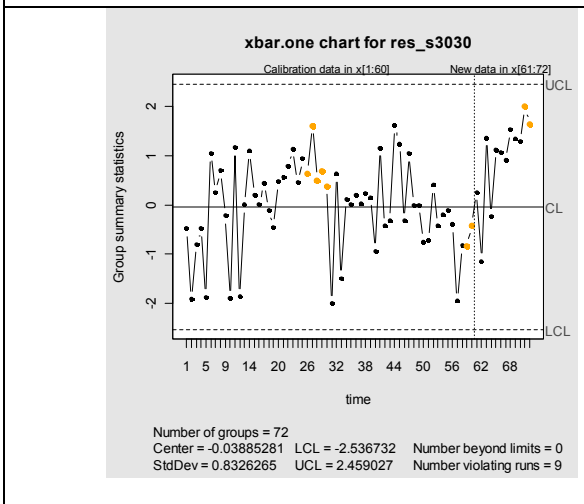
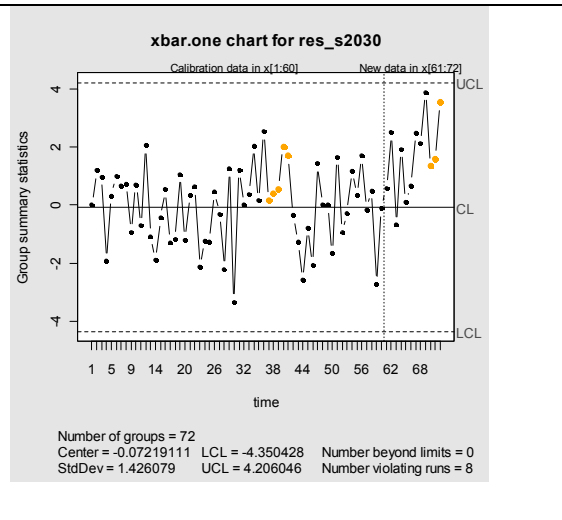
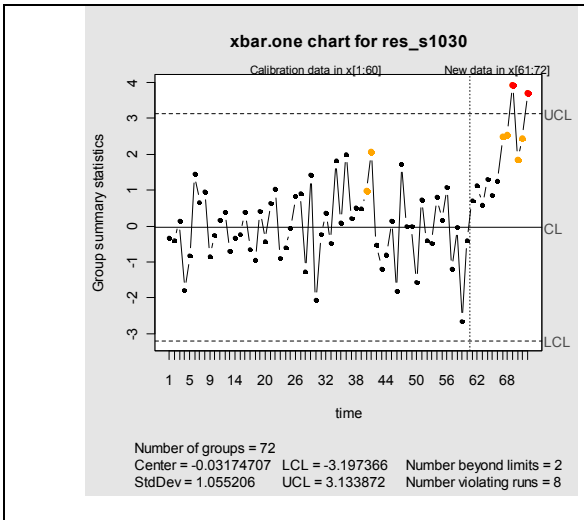
תחילה מופיעים התרשימים עבור הסדרות s1000, s2000 ו-s3000, המתאימות למודלים התאורטיים ללא שינוי, כאשר s2000 יוצרה כהפרש של s1000 ו-s3000. לאחר מכן, מוצגים אותם התרשימים עבור הסדרות עם שינוי מזמן 65 ומעלה, בגודל של 30%. יש לזכור שתרשימים מסוג זה מיועדים לגילוי חריגה חד-פעמית גדולה, או חריגה מספיק מתמשכת על-ידי כללי עזר.

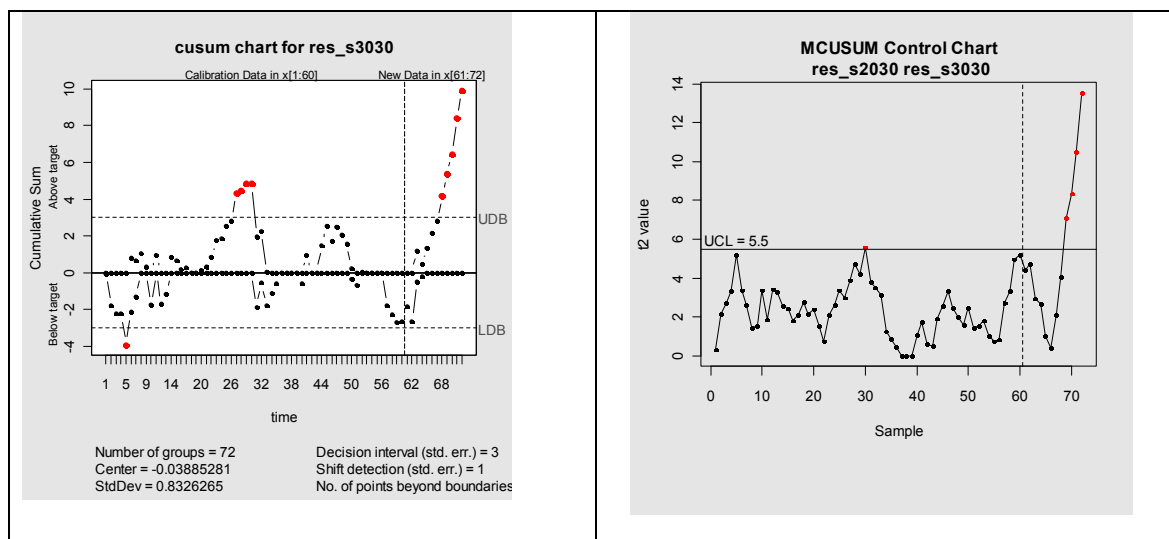
התרשימים החד ממדיים המתאימים מראים על סטיות קטנות אשר מצביעות על אפשרות של תהליך לא יציב, לכל אחת מהסדרות, למרות שהנתונים יוצרו מתהליך יציב. שוב אנו רואים שמעקב אחר מספר נקודות רב יחסית עלול להביא למצב של התראה שגויה. בתרשים המתאים לסכום שתי הסדרות, s1000, הנקודות החריגות מתאימות לאותו מקום שבו יש חריגה ב-s2000 שהיא אחת משתי הסדרות אשר נתוניה נכללו בסכום שיצר את הסדרה.



עבור הסדרות בהן יצרנו שינוי גדול בתקופה "אחרי", כל התרשימים מראים את השינוי - ראה טבלה להלן.







מכאן, בשלב מחקר זה, לא מצאנו יתרון רב בתרשים הרב ממדי, מעבר לשימוש בתרשימים שבהם כל סדרה נבדקת לחוד. לכן, לצורך מעקב על נפגעי תאונות דרכים יש משמעות ועניין רב **בבחינה נפרדת של כל סדרה**.

ראוי לציין שקיים שוני בין העניין שיש בשימוש בתרשימי הבקרה עבור נפגעי תאונות דרכים לבין מעקב על ייצור בתעשייה שכולל עשרות או מאות רכיבים. במקרה השני, לא מעשי לבחון מאות תרשימים. לכן, תרשים רב ממדי שימושי בעיקר כשלב של Screening שאחריו, במידה ומתגלה בעייה, מחפשים את מקורה.

## סיכום חלק שני

בסיכום, יש יתרון רב בשימוש בתרשימי הבקרה על בסיס השאריות ככלי מעקב על הנפגעים בתאונות הדרכים. הראינו את היתרון בבחינה סימולטנית של שני סוגי התרשימים: Shewhart ו-CUSUM.

בתרשים מסוג Shewhart גבולות הבקרה אופקיים, לכן קל למשתמש לתפוס היכן מתחולל שינוי, ומה מהותו - עליה, ירידה או חריגה חד פעמית, לעומת הצפוי. זה מתאפשר מאחר שהערכים המוצגים שהם שאריות, הם מנוכי מגמה ועונתיות, ומנורמלים.

בשני סוגי התרשימים: Shewhart ו-CUSUM, לאחר שלב ראשון של חישוב הפרמטרים הנדרשים לבניית תרשימי הבקרה על-פי התקופה "לפני", קל לחשב את הערכים המבוקרים על-ידי התרשים בתקופה "אחרי", וקל לשרטט את תרשימי הבקרה. מה שנדרש הוא רק חישובים אלמנטריים שניתנים לביצוע אף בעזרת מחשבון, ואפשרות לשרטוט גרפים פשוטים. עובדה זאת מאפשרת לשלב את התרשימים במערכת מידע, ואפילו לשרטט אותם ידנית. לכן יש יתרון מעשי למעקב אחרי מצב הבטיחות השוטף.

החיסרון בשיטה שבה בוחנים שאריות הוא שלערכים המופיעים בתרשים אין למעשה מובן, מאחר והם לא מבטאים בערכים של מספר נפגעים, אלא במונחים של שאריות.

יצוין כי שיטות חדשניות, בספרייה surveillance אשר בחבילת R, מאפשרות לבנות תרשימי בקרה על בסיס הערכים הצפויים על-פי המודל, וגבולות בקרה במונחים של מספרי נפגעים. בכך מתאפשר

מעקב אחרי הערכים הממשיים של הסדרות המבוקרות. שיטות אלה פותחו לאחרונה עבור נתונים מהתפלגות פואסונית וגם בינומית שלילית, ואלה ההתפלגויות המתאימות לנתוני נפגעים. אולם, גבולות הבקרה בתרשימים אלה אינם קווים אופקיים, המקשים על המעקב. כמו כן, קשה להסיק אם החריגה מגבולות הבקרה היא גדולה או קטנה באופן משמעותי ביחס לצפוי, בהתחשב בשונות הצפויה באותה נקודת זמן. יתר על כן, החישובים מורכבים בהרבה לעומת השיטות שהצענו במחקר הנוכחי.

עם זאת, רצוי היה להמשיך במחקר כדי להשוות ביתר עומק את השיטות האלה לעומת השיטות המופיעות במסמך זה. בפרט, ראוי לבדוק האם יש לאמץ אותן ככלי בקרה בנוסף לתרשימים שהמלצנו, דהיינו Shewhart ו-CUSUM על בסיס השאריות.

## מראי מקום

מהלאל, ד., הקרט, ש. (1976). מערכת הקצאה של משאבים בטיחותיים על פני רשת דרכים. פרסום 76/3, המרכז לבטיחות בדרכים.

גיטלמן ו., דובא א. (2009) פרק מתוך בחינת מגמות במספרי ההרוגים בתאונות הדרכים בשנת 2008 של הרשות הלאומית לבטיחות בדרכים.

<http://www.rsa.gov.il/InformationResearchCenter/StatisticalInformation/2008/Documents/megamot%202008/perek%201.pdf>

Al-Osh, M.A., and Alzaid, A.A. (1987) "First-order integer valued autoregressive (INAR(1)) process", *Journal of Time Series Analysis*, 8, 261-275

Borror, C. M., Keats, J. B. and Montgomery, D. C. (2000). "Robustness of the time between events CUSUM". *International Journal of Production Research*, 41, 3435-3444.

Bortkiewicz, L. von (1898) *Das Gesetz der Kleinen Zahlen*. Teubner: Leipzig

Brännäs, K. (1995) "Explanatory Variables in the AR(1) Model" *Umea Economic Studies No.381*, University of Umeå

Brillman, J.C., Burr, T., Forslund, D., Joyce, E., Picard, R. and Umland, E. (2005). "Modeling emergency department visit patterns for infectious disease complaints: Results and applications to disease surveillance". *BMC Medical Information and Decision Making* (594), 1-14.

Brook, D. and Evans, D. A. (1972). "An approach to the probability distribution of CUSUM run length". *Biometrika*, 59, 539-549.

Burkom, H.S., Murphy, S.P., and Shmueli, G. (2007). "Automated time series forecasting for bio-surveillance". *Statistics in Medicine*, 26(2), 4202-4218.

Cameron, A. C. and Trivedi, P. K. (1986), "Econometric models based on count data: Comparisons and applications of some estimators and some tests," *Journal of Applied Econometrics*, 1, 29-53.

Cameron, A.C., and Trivedi, P.K. (1998) *Regression Analysis of Count Data*. Cambridge University Press, Cambridge, UK.

Cameron, A.C., and Trivedi, P.K. (1999), "Essentials of count data regression", in Badi H. Batalgi ed., *A companion to Theoretical Econometrics*, 2001, pp. 331-348, Blackwell, Oxford (U.K.)

Cox, D.R. (1981) "Statistical analysis of time series: Some recent developments". *Scandinavian Journal of Statistics* 8, 93-115.

Crosier, R.B. (1988) "Multivariate Generalizations of Cumulative Sum Quality Control Schemes", *Technometrics* 30, 291-303.

Davis, R.A., Dunsmuir, W.T.M., and Wang, Y. (2000) "On autocorrelation in a Poisson regression model". *Biometrika* 87, 491-505.

Davis, R.A., Dunsmuir, W.T.M., and Wang, Y. (1999) "Modeling time series of count data" In *Asymptotics, Nonparametric, and Time Series*, Ed.S. Ghosh, 63-114, New York: Marcel-Dekker.

Davis, R. A., Dunsmuir, W. M., Wang, Y., and Street, S. (2001) "Modeling time series of counts". June 25, 2001. Satellite Meeting of Japan-US Seminar on Time Series, ISM, Tokyo, JAPAN: Modeling Time Series of Counts.

<http://www.stat.columbia.edu/~rdavis/lectures/tokyo01.pdf>

- Davis, R.A., and Wu, R. (2009) " A negative binomial model for time series of counts" *Biometrika*, 96(3), 735-749.
- Edgar S. F. (2011). MCUSUM: Multivariate Cumulative Sum (MCUSUM) Control Chart. R package version 1.0.
- <http://CRAN.R-project.org/package=MCUSUM>
- Fisher, G.R. and Mosher, W.W. (1968). Application of control chart techniques to the analysis of traffic accident data for selective enforcement purposes. Report No. 68-33, Institute of Transportation and Traffic Engineering, University of California.
- Fisher, G.R. (1970). On the effectiveness of statistical control chart techniques in selective enforcement applications. Report No. 70-12, Institute of Transportation and Traffic Engineering, University of California
- Forsberg. L., Jeffery. C., Ozonoff. A. and Pagano. M. (2006). A spatio-temporal analysis of syndromic data for biosurveillance. In: *Statistical Methods in Counter-Terrorism: Game Theory, Modeling, Syndromic Surveillance, and Biometric Authentication*, Springer.
- Fricker, R.D., Jr.' Knitt, M. ,C., and Hu, C.X., (2008) . 'Comparing directionally sensitive MCUSUM and MEWMA procedures with application to biosurveillance". to appear in *Quality Engineering*.
- Guria, J. and Mara, K. (2000). "Monitoring performance of road safety programmes in New Zealand" . *Accident Analysis & Prevention* 32 (2000), 695-702.
- Guria, J., Jones, W., Leung, J. and Mara, K. (2003). "Alcohol in New Zealand road trauma". *Appl Health Econ Health Policy*, 2(4), 183-90.
- Hohle, M. (2007). "Surveillance: An R package for the monitoring of infectious diseases". *Computational Statistics*, 22, 571-582.
- Hohle, M. and Paul, M. (2008). "Count data regression charts for the monitoring of surveillance time series". *Computational Statistics & Data Analysis* 52, 4357-4368.
- Hausman, J.A., Hall, B.A. and Griliches, Z. (1984) "Econometric models for count data with an application to the Patent-R&D relationship" *Econometrica*, 52, 909-938
- Hunter, J. S. (1986). "The Exponentially Weighted Moving Average". *Journal of Quality Technology*, 18, 203-210.
- Jung, R.C. and Tremayne, A.R. (2010). "Useful models for time series of counts or simply wrong ones? " *ASTA-Advances in Statistical Analysis*
- Kuo, T.I., and Lin, C.S.(2009)." Run-length percentiles of multivariate Poisson control charts". *The IEEE International Conference on Industrial Engineering and Engineering Management 2009. IEEM 2009*
- Lai, T. (1995)." Sequential change-point detection in quality control and dynamical systems". *Journal of The Royal Statistical Society, Series B*, 57, 613-658.
- Lotze, T. and Shmueli, G. (2008). Ensemble forecasting for disease outbreak detection, 23<sup>rd</sup> AAAI Conference on Artificial Intelligence, Chicago, July 2008.
- Lotze, T., Murphy, S.P, and Shmueli, G. (2008). "Preparing biosurveillance data for classic monitoring".*Advances in Disease Surveillance*
- Lowry, Cynthia A. and Woodall, William H. and Champ, Charles W. and Rigdon, Steven E.(1992). "A Multivariate Exponentially Weighted Moving Average Control Chart". *Journal of Quality Technology* 34.
- Ljung, G. M. & Box, G. E. P. (1978), "On a Measure of lack of fit in time series models," *Biometrika*, 65, 297–303.

- Lucas, J. M. (1976). "The design and use of V-Mask control schemes". *Journal of Quality Technology*, 8, 1–12.
- Lucas, J. M. (1985). "Counted data CUSUM's". *Technometrics*, 27, 129-144.
- MacDonald, I.L., & Zucchini, W. (1997) *Hidden Markov and Other Models for Discrete-valued Time Series*. Chapman and Hall, London
- McKenzie, E. (1986) "Autoregressive moving average processes with Negative Binomial and Geometric marginal distributions" *Advances in Applied Probability*, 18, 679-705.
- McKenzie, E. (1988) "Some ARMA models for dependent sequences for Poisson counts" *Advances in Applied Probability*, 20, 822-835.
- Montgomery, Douglas C. (2009). *Statistical Quality Control: A Modern Introduction* (Sixth ed.). Hoboken, New Jersey: John Wiley & Sons.
- Muscatello, D. (2004). "An adjusted cumulative sum for count data with day- of- week effects; Application to influenza-like illness" . Presentation at Syndromic Surveillance Conference, Boston, MA.
- Nelson, L. S. (1984). "The Shewhart control chart - Tests for special causes". *Journal of Quality Technology*, 15, 237–239.
- Pierce D., & Schafer D (1986). "Residuals in Generalized Linear Models". *Journal of the American Statistical Association*, 81, 977-986.
- Pierchala, C.E. and Surti, J. (1999). Control charts as a tool in data quality improvement. Report No. DOT HS 809 005, National Highway Traffic Safety Administration.
- Rossi, G., Lampugnani, L., and Marchi M (1999) "An approximate CUSUM procedure for surveillance of health events". *Statistics in Medicine*, 18, 2111–2122
- Scrucca, L. (2004). "qcc: an R package for quality control charting and statistical process control". *R News* 4/1, 11-17.
- Schabenberger O. (2005). "Introducing the GLIMMIX procedure for Generalized Linear Mixed Models" SAS Institute Inc. 2005. Proceedings of the Thirtieth Annual SAS® Users Group International Conference. Cary, NC: SAS Institute Inc.
- Snyder, R.D., Martin, G.M., Gould, P. and Feigin, P.D. (2007) "An assessment of Alternative State-Space Models for Count Time-series" Working paper 4/2007 Monash University  
<http://www.buseco.monash.edu.au/depts/ebs/pubs/wpapers/>
- Testik, M. C., McCullough, B. D. and Borrór, C. M. (2006). "The effect of estimated parameters on Poisson EWMA control charts". *Quality Technology of Quantitative Management* 3(4), 513-527
- WenSu, L. & Cel, J (2008). "Count data models in SAS". Proceedings SAS Global Forum 2008, paper 371-2008.
- West, M., and Harrison, P.J. (1997). *Bayesian Forecasting and Dynamic Models*, 2<sup>nd</sup> Ed. New York, Springer.
- Wimmer, V., and Hohle, M. (2008). The function 'algo.glrnb' in the R-package 'Surveillance'.
- Winkelmann, R. (2008). *Econometric analysis of Count Data*. Springer. Sixth Edition
- Yahav, I., Lotze, T. and Shmueli, G. (2011). "Algorithm combination for improved performance in bio-surveillance" . In: D. Zeng et al (eds.) *Infectious Disease*

Informatics and Bio-surveillance, Integrated Series in Information Systems, 27,  
DOI10, 1007/978-1-4419-6892-0\_8, Springer Science +Business Media, LLC.