



# TARGET BACKCLOTH, SERIES LENGTH, AND THE ACCURACY OF GEOGRAPHIC PROFILING

## SIMULATION ANALYSIS OF TARGET BACKCLOTH, SERIES LENGTH, AND THE ACCURACY OF GEOGRAPHIC PROFILING

Michał GÓRSKI

*College of Inter-Faculty Individual Studies in Mathematics and Natural Sciences, University of Warsaw, Warszawa, Poland*

### Abstract

The main aim of this research was to establish a minimum series length when crime opportunities are not distributed at random. In addition, the behaviour of two methods of assessing the accuracy of a geographic profiling algorithms were analysed. The second objective was to analyse the existence and properties of the buffer zone in the created model. For the purpose of this research, a simulation was used. Data showed significantly different behaviour in the two tested methods of assessing the accuracy of geographic profiling, with hit score percentage being the significantly more sensitive measurement. The tests allowed all of the effects attributed to the buffer zone to be obtained, despite the fact that it was not included in the model itself. For series as long as nine offences accuracy in non-random conditions was similar to series length five and uniform distribution of opportunities.

### Keywords

Geographic profiling; Target backcloth; Buffer zone; Distance error; Hit score percentage.

*Received 16 July 2021; accepted 17 December 2021*

### Introduction

Geographic profiling (GP) is a set of methods focused on allowing law enforcement agencies to prioritise area (or some subset of possible suspects) based on its geographical location in the relation to the locations of the crimes within crime series (Rossmo, 2000; Chainey, Ratcliffe, 2008). Those methods include specialised computer software that highlights specific area as more probable location of the actual offender (Chainey, Ratcliffe, 2008). This software is mostly based on distance travelled by the offender and usually does not take into account environmental factors (Chainey, Ratcliffe, 2008). Those factors, called target backcloth, are properties of the area that are

favourable from the point of view of possible offenders, and influence their decision making (Brantingham, Brantingham, 1991). There are exceptions to this rule with software that does include more spatial information, like bayesian approach to geographic profiling, which requires not only general distributions of distances between crime locations and offenders home (called journey-to-crime distance), but also locations of offenders that have previously committed crimes in closes vicinity (Levine, Block, 2011). As Lundrigan, Czarnomski and Wilson (2010) mention, the target backcloth is a concept that is closely connected to opportunity. The authors say that a ‘backcloth is made up of dynamic and uncountable dimensions and features that provide potential opportunities for crime’ (p. 19).

This definition is quite clear, while not limiting the character or type of variables that should be included in the target backcloth. There are a number of studies that show what specific variables may be part of a target backcloth. In the above-mentioned analysis, Lundrigan et al. (2010) show that in series of sexual assaults offenders choose a specific environment, but as they mention their analysis was limited to the variables that were originally recorded by the police, thus some significant factors might be absent. Bernasco and Block (2009) conducted a more thorough analysis on robberies in Chicago that included the ethnic and racial composition of an area, gang activity, the number of potential targets, offender demographics, distance travelled, and more. The authors found that all of their factors had some kind of impact on the target selection process, but these are most probably not the only variables that should be taken into account. The problem of the target backcloth has significant practical implications. As Lundrigan et al. (2010) describe it, GP is closely connected to this concept and has huge practical implications. Rossmo (2000) as well as Canter, Coffey, Huntley and Missen (2000) both mention the target backcloth as one of the factors that is closely related to GP and that may influence its accuracy. Unfortunately, how the distribution of opportunities influences the accuracy of GP is still unknown. The reasons why there is little research into this particular problem are numerous.

First of all, a method of measuring the effect of a single target backcloth on GP accuracy has not yet been discovered. As described above, the target backcloth is a broad subject by definition, and what constitutes a favourable environment is still not exactly clear. The problem is measuring the number of appropriate targets in an area. Each offender may have different preferences within the same crime type, and thus different areas will be perceived as rich in possible targets. This makes it almost impossible to measure the richness of opportunities in each area, and as a result the effect on the accuracy of GP algorithms. The differences in GP accuracy in different areas may be due to target distribution, but other factors may also have an influence. Thus, smaller accuracy may be caused by a larger buffer zone, a specific road grid, available means of transportation, the size of the area in question, or finally the target backcloth. This is probably the reason why Snook, Taylor and Bennell (2005) mention that there is little to no evidence for the influence of target backcloth on GP accuracy. Rossmo (2005) gives a compelling example of an offender hunting prostitutes. His area of criminal activity would

be mostly restricted to the red light district due to the target opportunities, but that does not mean the offender would be living there.

In the literature, there are generally two distinct methods of GP algorithm measurement. The first is the distance from the offender's location (commonly called anchor point, in most cases it is offenders home, but this does not have to be the case; Rossmo, 2000) to the point of maximum probability, which is called error distance (Rich, Shively, 2004). This can be used to evaluate simple methods (point of minimum distance, first or last offence, mean, and so on) and predictions made by computer software (Rigel, Dragnet, or similar). The second is search cost, which is a method that calculates the surface area of a plane that has a greater probability than the residence of the actual offender. A slightly different method called 'hit percentage' or 'hit score percentage' calculates the percentage of this area as a part of the whole search area, giving an estimation of the extent to which the search area can be reduced by GP. This method is only used to evaluate the accuracy of GP software, and is described along with others in a report created for the National Institute of Justice (NIJ) based in Washington, D.C. (Rich, Shively, 2004). In response to this report, Rossmo (2005) argued that only search costs or the hit score percentage method allow for the appropriate estimation of GP accuracy. The author gave examples of cases where the shape of the jeopardy surface was irregular, thus when the search cost function was applied the profile was highly accurate. However, the distance from the point of maximum probability was large, making the profile seem inaccurate. The argument here is that in reality the profile was accurate, since the offender lived in the most probable area, but when accuracy was measured by distance from the maximum probability it did not appear to be accurate. The assumption is that when searching for an offender, police will follow the shape of the jeopardy surface. If this was true, the conclusion would obviously be true. It is also unknown how often it happens that the shape of the jeopardy surface is so irregular that the accuracy calculated with distance from the point of maximum probability shows significantly different results than when using the search cost function. The other issue is whether this irregularity is specific to Rossmo's algorithm, or whether it may happen when applying different functions to create the jeopardy surface.

## Number of offences

The number of offences used to evaluate GP methods also poses a problem. While Rossmo (2000) argues that a series must consist of at least five offences for GP to be accurate, series this long are very rare in the literature. For example, research by Lundrigan et al. (2010) on sexual assault consisted of 76 offenders, where 34% had committed only two offences, 28% three, and only 23% between five and fourteen crimes. The mean series length was 3.8 and the median was three crimes. Considering that crimes were collected between 1970 and 2002, this demonstrates how hard it is to gather appropriate data. Still, this research would not be useful in determining how many offences series should consist of to use GP algorithms. This is, most probably, the reason why Rossmo (2000) used computer simulation to create an estimate of minimum series length. It allowed series of any desired length to be generated. This method was criticised by Snook et al. (2005), who argued that this simulation overly simplifies offenders' target selection process. The algorithm for generating series chose a random location around the offender's home using a distance decay function (Snook et al., 2005). It was argued that in this model it was obvious that the values would, as the series progressed, centre on the home location of the offender. On the other hand, the simulation done by Rossmo was probably to illustrate accuracy in optimal conditions and show that in any real-life situation longer series may be needed. How much longer, however, is still unknown, but this supports the statement made by Rossmo (2005) that using shorter series for the purpose of testing GP might lead to false conclusions. Other approach was used by Levine and Associates (2000), who divided sample of serial crimes into three groups, first one were series of length between three to five, second six to nine and third ten and more. While authors were able to show improvement with series length the construction of this research does not enable to assess exact preferable series length. The series length still is one of the main properties of crime series that influences geographic profiling accuracy. It is often difficult to obtain significant sample with long crime series that would allow to assess accuracy for this type of crimes. Research conducted by Górski (2021) is a good example, since sufficient predicted accuracy was for crime series longer than most of the data in available sample. This would show that it is difficult to estimate when crime series is long enough for GP software to be used, or to be of significant help.

## Discrete or continuous model

There is another reason the model used by Rossmo (2000) might not create an accurate simulation of offenders' behaviour. Even assuming the uniform distribution of targets across the entire area of the offender's activity, those opportunities are not guaranteed to follow a continuous distribution. Continuous distribution would not only mean that the opportunities are uniformly distributed in the area, but also that the offender may choose any location at any distance from their residence to commit a crime. This may be true in the case of street robberies (although it is still doubtful), but if one considers commercial burglary it obviously is not. A good example would be a case in which the offender targets small shops in a residential area. Those shops are usually uniformly distributed around residential properties, but this offender would still be restricted to the points where shops are located. In reality, the author would argue that only a discrete model is appropriate and that targets in the area are always located at particular points, rather than continuously. This is further supported by research on target selection patterns in which authors use discrete models to describe criminals' spatial behaviour (e.g. Bernasco, Block, 2009). It could be argued that most probably the continuous model did not influence the results concerning the number of crimes needed for the application of GP. One should still consider the implications of using a discrete model. For example, this kind of approach might strongly influence the effects of the buffer zone. The buffer zone is a concept in which offenders choose to commit crimes further from home to avoid recognition and, as a consequence, capture. The area around offenders home (or more generally, around his anchor point) in which he refrains from committing crimes due to the possibility of recognition is called buffer zone. If the distance that the offender has to travel to the nearest possible target is greater than the buffer zone, the buffer zone would have no influence on crime distribution. A similar argument is made by Canter and Youngs (2008), who mention that the buffer zone might not be visible when the offender is choosing a specific target. One should consider the additional possibility that, in the case of discrete opportunities, the offender may not need to search for a specific target. The effect attributed to the buffer zone might be visible if on average the offender must travel some distance to the first favourable opportunity. In the example of the offender targeting small shops, if on average the distance considered by the offenders as safe to offend (the buffer zone) is significantly smaller

than the average distance to the first available target, the buffer zone itself would have no visible effect on target selection. However, when considering distance to crime we would see what could be interpreted as the buffer zone, but which would have nothing to do with the real buffer zone. This scenario where the offender has to travel some distance to the closest opportunity is more probable than it would seem. This is due to the fact that when considering journey-to-crime (distance between offenders anchor point and crime location) we use one-dimensional probability, but when we consider an entire area we deal with probability in two dimensions. This effect is well described by O'Leary (2011), who shows that one-dimensional distribution with a buffer zone might not mean that when considering two-dimensional probability there will still be a visible buffer zone.

Consider three areas, one circle up to one kilometre from the offender's home, a second ring around the home between one and two kilometres, and a third ring between two and three km. The surface area of each of these is respectively  $\pi \text{ km}^2$ ,  $3\pi \text{ km}^2$ , and  $5\pi \text{ km}^2$ . This means that in the second area there are probably three times more opportunities than in the first (assuming uniform distribution of opportunities); however, in the third area there are fewer than double the number of opportunities in the second area. This indicates that a lower number of offences closer to an offender's residence may be due to the number of opportunities elsewhere rather than the offender's unwillingness to commit crimes close to their home. This example also shows that there will be a large increase in number of opportunities in close proximity to the offender's home that will slow down with distance. As explained by Rengert, Piquero and Jones (1999), the number of crimes should at first increase with distance from the offender's home, then start to decrease after a certain point. This point is supposed to be the buffer zone, but as described above this is exactly the same effect that we should expect to see in a model without a buffer zone but with the discrete distribution of targets. Another argument in favour of the buffer zone was made by Canter and Larkin (1993). When the linear regression between the maximum between-crime distance and maximum journey-to-crime distance (the regression equation was  $y = 0.84 \times x + 0.61$ ) is considered, the constant in the regression equation (0.61 miles) was smaller than the average minimum distance travelled by the offenders (1.53 miles). The authors concluded that the buffer zone was responsible for the minimum distance travelled on average being over two times higher than what the maximum distance should have been.

## Aim

The aim of the current study was to establish the minimum series length that allows for the application of GP. As was described, method proposed by Rossmo (2000) is not without its flaws and new approach may be necessary. New technology, GIS software, may allow for more complex models that would allow to include more factors. Since, as was described, it is almost impossible to collect a sample of crime series long enough, the simulation method was chosen. Using simulation allowed also to avoid other factors that might impact results. Those were existence of anchor points other than offender residence and flawed linkage analysis. Some modifications were made to the model used by Rossmo (2000) to establish the minimum number of crimes necessary to apply GP. This includes two factors: the non-continuous, discrete distribution of opportunities in the area; and including the target backcloth. Target backcloth was included since this was element missing from original research, and including it allowed for analysis of non uniformly distributed crime opportunities. To fulfil this goal, the simulation was conducted in two conditions. The first is a random condition, where possible crime locations are distributed over the area with uniform probability; the second follows real-life locations of actual burglaries, so that opportunities are not only at certain points, but are also clustered – as in real-life scenarios. From those two sets of points, one random, other based on real locations artificial crime series were created. Common measurements used in the research on offenders' spatial behaviour were used to describe the properties of the model. These include minimum and maximum journey-to-crime distance, maximum between-crime distance (the maximum distance between crime locations in the series), and the number of commuters and marauders in the sample. The model does not include a buffer zone, but despite that in both conditions it was expected that results would be found that were similar to the effect described by Canter and Larkin (1993) attributed to the buffer zone. It was also predicted that due to the discrete nature of the possible targets there would be a decline in the number of very short trips taken by the offenders.

The second aim was to investigate the relationship between series length and GP accuracy depending on the two conditions. It was expected that in a group without a target backcloth with longer series both measurements would show increased accuracy, whereas in the group with the target backcloth this increase might be smaller or even stop at some point. Hence, it was expected that in a group with a target

backcloth longer series would be necessary to obtain similar accuracy as the group without a target backcloth and a series length of five crimes. Since there is no research on the impact of the target backcloth on GP and series length, it was not clear how long these series should be exactly.

## Method

For the purpose of this study the locations of 6,115 burglaries in Warsaw, Poland and its suburbs were obtained with the help of the Polish police. No subgroup was extracted from this sample, the assumption being that the locations of the crimes corresponded to the general target distribution. At the same time, because there were no real-life offenders, there was no problem with whether the offenders had the same preferences (Bernasco, 2009). This hypothetical model also allowed for the omission of the problem of what the opportune location for a particular offender consists of and focuses on the sole impact of the target backcloth and the density of possible target locations. The same number of fictional offences were drawn at random from the same area. To describe the differences between the two conditions, the method described by Chainey and Ratcliffe (2008) for analysing crime hotspots was used, that is, nearest neighbour distance. In the real-life sample, it was expected that crimes would show a shorter distance to the nearest neighbour, while also displaying a longer maximum distance. For the random sample, this distribution would be more similar to normal distribution, with a smaller maximum but a greater mean and median. The locations of offenders' homes were generated at random, with the area from which they could be selected being limited to 64% of the middle of the original surface. This was done so that offenders' residences would be at some distance from the border of the area, to minimise the impact of offenders only having opportunities on one side of their residence. For each of the offenders, weights were calculated for each of the possible crime locations. For random condition those locations were at random, for target backcloth conditions those were real life crime locations. An exponential function was chosen in order to generate the series. This is because it is one of the most commonly used functions in research on journey-to-crime, while it is used to create the distance decay function in research on GP as well. In addition, this function also does not include the buffer zone, so if there was one it would be solely due to the target distribution. For journey-to-crime, an attempt was made to follow the exponential distribution,

so when calculating weights a slight modification had to be made. This again is due to the difference in the probability in the two-dimensional and one-dimensional journey-to-crime. For offence  $i$  at distance  $d_i$  from the offender's residence, weights  $x_i$  were calculated using the following formula:

$$x_i = \exp(-A * d_i) / d_i$$

Later, all of the weights were divided by their sum for this particular offender. In the next step, from the whole sample of crimes a given number of offences (series length) was selected based on the calculated weights. The division of the exponential function by distance was due to the transition from the two-dimensional to the one-dimensional distribution (cf. O'Leary, 2011). For each condition, a check was done to measure whether journey-to-crime distribution was statistically different than the exponential distribution. All calculations were made in R software version 3.3.3, graphs were made using ggplot library (Wickham, 2009).

## Value of the constant

The value of the constant A in the given formula was not estimated empirically. Since this constant determines the importance of distance in the model, it was crucial to test for as many reasonable values as possible in order to analyse the behaviour of the model in different conditions where the target backcloth has a bigger or smaller influence. For larger A, there would be a bigger difference in weights between possible targets, therefore representing offenders that choose targets based on their proximity. A smaller constant would mean that targets are selected more randomly, therefore making areas richer in opportunities more probable, since the probability of the area would resemble the proportion of opportunities. To test the model in different circumstances, results for two values were described. In summary, 90 different series lengths and different values of the constant were tested. Due to the size of this article and for clarity reasons, most of the results will be shown for a constant A value of 0.234174, which is based on research by Hammond and Youngs (2011) on serial burglars. In some cases, the results will be compared to those obtained with A equal to 0.04574 (obtained by Canter and Hammond, 2006). In the analysis of the effect of target backcloth on the buffer zone, a series length of three was chosen. This is significantly lower than what is expected by Rossmo (2000) as the minimum series

length, but, as described above, longer series are rare in studies and the aim here was to relate the obtained results to the effects observed in other studies. The exception will be the analysis of the impact of series length on accuracy, where the results will be shown for all tested series lengths. For comparison purposes, results obtained for series that consisted of five incidents and a random distribution of targets were used, as these are the conditions closest to those used by Rossmo (2000). If the reader would like to know the properties of the model for different values, or possibly the different functions for generating samples, they are available upon request.

## Results

To show the differences between the random and real-life crime samples, the distribution of the nearest neighbour distance was analysed first. For random conditions, the maximum was 0.72 and the minimum 0.0063. The same values for real offences were 2.46 and 0.0007 respectively. The mean was 0.14 for the target backcloth (median = 0.09) and 0.23 for random offences (median = 0.22). The density of the nearest neighbour distance has been plotted in Figure 1.

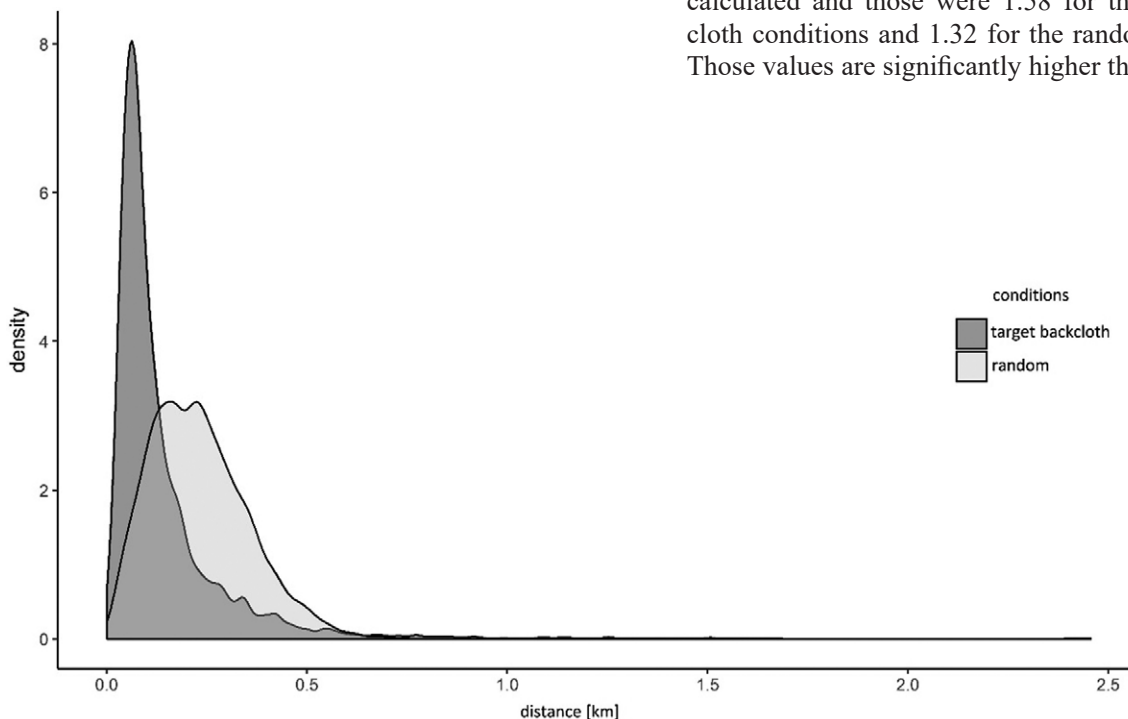


Figure 1. Density of nearest neighbour distances.

## Buffer zone

To test if the effect usually attributed to the buffer zone appeared, the mean of the minimum journey-to-crime was compared to the constant in the linear regression between the maximum between-crime distance and the maximum journey-to-crime distance. For  $A$  equal to 0.234174 and a series length of three, the regression function was given with formula  $y = 0.85 \times x + 0.91$ , while a mean minimum journey-to-crime was equal to 1.86. For the random distribution of opportunities, a similar effect was observed: with the regression function  $y = 0.76 \times x + 0.48$ , the mean minimum distance was 1.28. In addition, journey-to-crime distribution was investigated using the Kolmogorov-Smirnov test, and there was a statistically significant difference between the sample and the exponential distribution for the target backcloth conditions ( $D = 0.1$ ,  $p < 0.01$ ), while there was no such difference for the random distribution of offences ( $D = 0.05$ ). The density of offences for both conditions is shown in Figure 2. It is important to note that for other values of  $A$  a similar effect was visible, and that the constant in the linear regression function was only greater than the mean minimum distance travelled by offenders eight times out of the 90 tested conditions. Although it has to be noted that for longer series constant in linear regression was often negative. In addition, the maxima of the kernel density functions were calculated and those were 1.58 for the target backcloth conditions and 1.32 for the random conditions. Those values are significantly higher than the average

distance between offence locations (0.14 for the target backcloth and 0.23 for the random conditions). The mean journey-to-crime was 4.69 (median = 3.74)

for the target backcloth conditions, and 3.8 (median = 2.88) for the random conditions.

To check consistency of obtained results for series length 3 and A equal to 0.234174, test was repeated ten thousand times. It was done only for backcloth conditions, results can be seen in Figure 3. Only seven times in ten thousand constant was greater than mean minimum JTC, mean value of constant was 0.99, while mean (of means of minimums) JTC was 2.13.

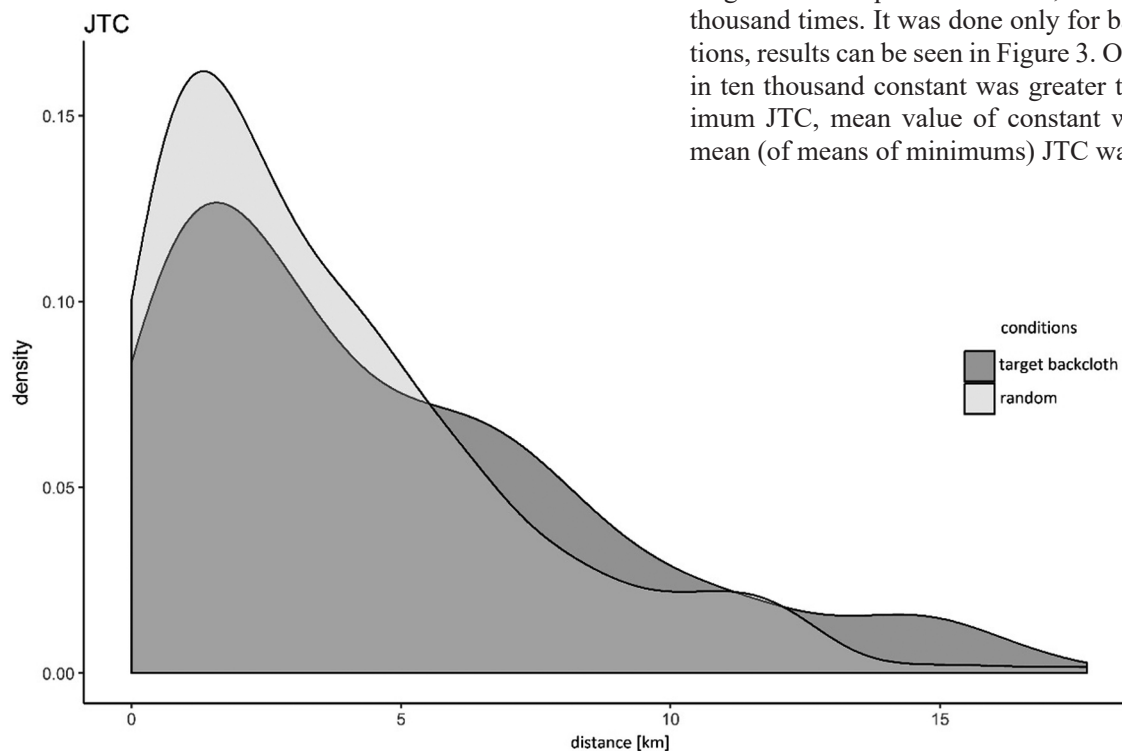


Figure 2. Journey-to-crime distribution density.




Figure 3. Compared distributions of constants in linear regression function and mean minimum JTC.

## Geographic profiling accuracy

For the purpose of this research, two methods of calculating accuracy were used. One was error distance, the other hit score percentage. In Figures 4 and 5 it was shown how those measurements behave depending on the length of the series. Figure 4 was created using error distance as a measurement of accuracy. As can be seen, no significant improvement is visible for series longer than three offences for backcloth conditions.

To test whether this was true, the Kruskal-Wallis test was conducted. In this test, for a particular series length all of the series of offences that were equally long or longer were included. The tested groups consisted of series of equal length. This was done for series with and without the target backcloth. The point at which there was no statistical difference between the groups was assumed to be the point where longer series did not improve accuracy when measured by distance from the point of maximum probability. The results are shown in Table 1.

Figure 5 was created in the same manner based on the same sample, but using the hit percentage method to establish the accuracy of the profile. There is a visible increase in accuracy with the length of the series for both conditions (random and including the target backcloth), although better accuracy is always obtained in random conditions.




Figure 4. Progress of distance error accuracy for two tested conditions.

To answer how many offences are needed in the target backcloth conditions to obtain a similar accuracy to the random distribution of opportunities and the accuracy from series with a length of five, each series length was compared to the series of five offences in the random distribution condition according to hit percentage score. This method of measuring accuracy was chosen to follow the methodology used by Rossmo (2000) and also due to the previous results, that is, a lack of improvement in accuracy with series length when using the distance error measurement. The distribution of accuracy was compared using both the Kolmogorov-Smirnov test and the Wilcoxon test. Both showed that for the target backcloth and a series length of nine there was no significant difference in accuracy from the random offences sample and the series with a length of five. The results were similar for different tested values of constant A as well. The values for both statistics can be seen in Table 2.

To test the stability of the accuracy calculated as a percentage of hit score percentage, the same method was conducted as with the distance to the maximum point measurement. Again the Kruskal-Wallis test was used. Results for both the methods of testing accuracy can be seen in Table 1. A final test was conducted to check if there were any differences in the accuracy among all the tested series lengths between the two conditions. In order to do this, two sets of tests were used: the Kolmogorov-Smirnov test and the Wilcoxon sum rank test. The results are shown in Table 3.



Table 1  
Table of Kruskal-Wallis rank sum results. Chi-squared values are given in the table

Series length	Error distance		Hit score percentage (%)		df
	Random offences	Target backcloth	Random offences	Target backcloth	
2	182.07**	53.85**	617.56**	348.98**	14
3	79.21**	23.62**	457.43**	184.23**	13
5	45.5**	19.47	328.51**	124.62**	12
6	43.33**	5.38	273.09**	60.84**	11
7	38.93**	5.46	232.03**	54.83**	10
8	26.92*	4.95	169.93**	43.38**	9
9	14.68	4.89	131.72**	33.47**	8
10	10.85	4.88	107.88**	27.88**	7
11	10.87	4.85	91.19**	20.38*	6
13	6.98	4.9	55.96**	12.88*	5
15	2.02	4.67	26.94**	10.34*	4
17	2.03	3	18.49**	7.93*	3
20	0.89	3.12	12.4*	3.07	2
25	0.13	3.2	3.73	2.55	1

\*\* p < 0.001, \* p < 0.05




Figure 5. Compared distributions of constants in linear regression function and mean minimum JTC.

Table 2

*Accuracy in target backcloth conditions compared to the random conditions sample and series length of five*

Series length	Kolmogorov-Smirnov	Wilcoxon
2	0.72**	684.5**
3	0.48**	2253**
5	0.44**	2290.5**
6	0.2*	3979**
7	0.21*	3802.5*
8	0.2*	3966*
9	0.19	4253.5
10	0.16	4277
11	0.13	4405.5
13	0.08	4813.5
15	0.08	4942.5
17	0.07	4887
20	0.09	5377.5
25	0.21*	6029*
30	0.11	5365

\*\*  $p < 0.001$ , \*  $p < 0.05$

## Discussion

It was found that using the described model, an effect similar to the buffer zone was clearly visible. What was surprising was that this was obtained in both conditions, showing that the discrete distribution of targets is enough to explain why the average minimum of journey-to-crime distance is much higher than the constant in the linear regression. This means that it is not necessary for opportunities to be clustered in particular areas to impact the distance decay function; what is enough is the uniform but discrete distribution of targets. Test was repeated ten thousand times for backcloth conditions and results show that obtained difference between minimum JTC and constant in linear regression equation was not accidental. Similarly for both conditions – random and target backcloth – there is a visible decline in the number of offences in close proximity to the offender's location. Thus, another argument used to show the buffer zone might be the result of the discrete distribution of targets. In the Figure 2 it is visible that both groups display behaviour attributed to the buffer zone. Since the mean distance between crimes was respectively 0.14 and 0.23 for the target backcloth and random conditions in the model without the buffer zone, one would expect that the journey-to-crime distance would be around half as

Table 3

*Differences between random and backcloth conditions in both accuracy measurements*

#	Error distance				Hit score percentage			
	Mean (median)		K-S test	Wilcoxon	Mean (median)		K-S test	Wilcoxon
	Target backcloth	Random offences			Target backcloth	Random offences		
2	4.37(3.38)	4.02(2.91)	0.12	5382	51.13(46.57)	42.75(27.2)	0.12	5623
3	3.21(2.03)	2.2(1.48)	0.19	5994*	22.95(7.99)	10.84(3.31)	0.22*	6117*
5	3.1(2.27)	1.24(0.78)	0.47**	7894**	2.79(0.85)	10.52(5.45)	0.44**	7709.5**
6	2.47(1.76)	1.16(0.88)	0.33**	6707**	6.02(1.72)	2.23(0.56)	0.22*	6434.5**
7	2.6(1.9)	1.36(0.94)	0.3**	6530**	5.5(1.84)	1.49(0.67)	0.31**	6716.5**
8	2.47(1.51)	1.23(0.89)	0.29**	6752**	4.25(1.88)	1.08(0.35)	0.38**	7209.5**
9	2.29(1.55)	0.97(0.72)	0.36**	7243**	3.8(1.18)	0.68(0.24)	0.4**	7496**
10	2.34(1.68)	0.95(0.67)	0.4**	7362**	3.65(1.52)	0.49(0.18)	0.51**	7760**
11	2.19(1.62)	0.9(0.7)	0.43**	7306**	2.96(1.48)	0.56(0.16)	0.47**	7615.5**
13	2.43(1.83)	0.93(0.69)	0.44**	7271**	2.53(0.95)	0.41(0.15)	0.44**	7590**
15	2.45(1.73)	0.74(0.58)	0.5**	7957**	2.09(0.84)	0.19(0.09)	0.57**	8395.5**
17	2.3(1.67)	0.81(0.65)	0.44**	7754**	2.28(0.89)	0.22(0.07)	0.56**	8291.5**
20	2.24(1.41)	0.74(0.63)	0.49**	7606**	2.17(0.68)	0.13(0.07)	0.56**	7978.5**
25	1.95(1.43)	0.68(0.57)	0.46**	7576**	1.14(0.52)	0.1(0.05)	0.54**	8079.5**
30	2.25(1.7)	0.64(0.58)	0.62**	8518**	1.54(0.67)	0.05(0)	0.72**	9082.5**

\*\*  $p < 0.001$ , \*  $p < 0.05$

much. The results show something significantly different: mean journey-to-crime, mean minimum journey-to-crime, and the location of the maximum kernel density function were all much greater than that value. This does not prove that the buffer zone does not exist, but only that there are other explanations to these kinds of results. In addition, as Canter and Youngs (2008) describe, there is the possibility that single offenders do try to avoid committing offences in close proximity to their homes, so the model with the buffer zone might be appropriate for these individuals.

Another important result concerns the measurements of the accuracy of the GP algorithms. As can be seen in Figures 4 and 5 and Tables 1 and 2, hit percentage is a more sensitive measurement that more often shows differences between groups in the random and backcloth conditions. It also showed more changes in accuracy with the increase of the series length. This supports the argument made by Rossmo (2005) in response to the NIJ report that error distance is not sufficient to show the accuracy of a geographic profile. With increasing series length, accuracy measured by hit percentage steadily increased, while there was no such effect in the distance error measurement. In the target backcloth conditions, after a series length of three there was no statistically significant improvement in error distance. It is important to note that in the current test Rossmo's formula was not used, rather an exponential function was applied, thus this effect is not limited to the Rossmo's criminal geographic targeting algorithm. Snook et al. (2005) argue that error distance allows human-made predictions to be compared with computer output, which is not possible with hit percentage or similar measurements. But this is not true if the point suggested by the human as the starting point for the search, which would be conducted in each direction the area covered until the offender was found, is equal to the area of a circle with a radius equal to the error distance. The current test suggests that error distance itself should be abandoned as a measurement of GP accuracy.

In addition, the obtained results support another statement by Rossmo in which he stresses the importance of the target backcloth for GP accuracy. In the present simulation, significantly longer series were necessary in the target backcloth conditions to obtain similar results as in the random condition for five offences. In the backcloth conditions it was necessary to have at least nine locations to obtain accuracy similar to the random conditions and five offences. It is important to note that when  $A$  was equal to 0.04574, as many as 17 crimes were needed to obtain similar results. This shows that in real-life conditions even more

offences might be necessary to obtain satisfactory results. This is very important result, since it shows that series length may be one of the most important factors when considering application of GP in specific cases. This result is also consistent with results obtained by Górski (2021) on Polish sample of offenders. In addition, as seen in Table 3, in almost all tested series lengths and in both used accuracy measurements there were significant differences between groups, showing possible impact of target backcloth on GP.

What is also important is that, contrary to expectations, there was no threshold in the target backcloth conditions when applying the hit score percentage method of measuring accuracy. The opposite effect was obtained when using error distance. With this measurement, the accuracy of the profile for the target backcloth conditions was significantly limited, showing no improvement with longer series. Upon closer analysis of the many generated profiles, it was concluded that when applying the target backcloth a significantly different spatial pattern was obtained. Comparing the results to the model created by Rengert (1996), it was discovered that for random conditions the results did reassemble what the author called the distance bias pattern. In the target backcloth model, a bimodal or directional bias (teardrop) pattern emerged. This means that either there is a separate secondary area of higher probability (with the offender's residence within it), or in one direction from the point of maximum probability the likelihood of finding the offender decreases significantly slower than in the opposite direction. This causes the residence of the offender to be at significantly larger a distance from the point of maximum probability, while still remaining in the area of high probability. Obviously, it is unknown how often this might happen in real life, but it still highlights the significant disadvantage of error distance as a measurement of accuracy. This again can have significant impact when analysing what kind of GP method is best for particular sample of offenders. Results show that hit score percentage is better assessment tool and should be preferred when searching for best GP algorithm or software.

Since the current analysis is based on a computer simulation, there is obviously a need for further research. Even so, some conclusions from the conducted tests seem to be universal and, at least to some degree, applicable to real-life offenders. First of all, it was shown that it is fairly easy to obtain a buffer zone-like effect in a model that in itself does not contain it. While it is not possible to conclude based on this that a buffer zone might not exist, it shows the need to develop new tools in the search for this effect. When

using measurements of GP accuracy, it was shown that error distance fails to measure difference in the accuracy for different series lengths. Hit percentage in the same conditions showed a steady increase in accuracy. This indicates that error distance is not an appropriate tool for comparing GP methods. While the results will not show how common this might be in real life, the fact that error distance accuracy was the same for a series length of three and above in the target backcloth conditions was staggering. This is evidence that error distance is a significantly flawed method for measuring accuracy and should not be used.

In conclusion, obtained results show that limit of five crimes per series is too low and that for application of GP higher threshold should be set, maybe even over three times greater. For choosing geographic profiling method hit score percentage is better method of assessment, as it is more sensitive and able to measure more subtle differences between profiles. For theoretical consideration it was found that most common effects attributed to buffer zone might actually be a result of discrete distribution of potential targets, thus new methods of finding said buffer zone (and, as extent, proving its existence) may be needed.

## References

- Bernasco, W. (2009). Modeling micro-level crime location choice: Application of the discrete choice framework to crime at places. *Journal of Quantitative Criminology*, 26(1), 113–138. DOI: 10.1007/s10940-009-9086-6.
- Bernasco, W., Block, R. (2009). Where offenders choose to attack: A discrete choice model of robberies in Chicago. *Criminology*, 47(1):, 93–130. DOI: 10.1111/j.1745-9125.2009.00140.x.
- Brantingham, P. L., Brantingham, P. J. (1991). *Environmental criminology*. Prospect Heights, IL: Waveland Press.
- Canter, D., Larkin, P. (1993). The environmental range of serial rapists. *Journal of Environmental Psychology*, 13(1), 63–69. DOI: 10.1016/s0272-4944(05)80215-4.
- Canter, D. V., Coffey, T., Huntley, M., Missen, C. (2000). Predicting serial killers' home base using a decision support system. *Journal of Quantitative Criminology*, 16, 457–478.
- Canter, D., Hammond, L. (2006). A comparison of the efficacy of different decay functions in geographical profiling for a sample of US serial killers. *Journal of Investigative Psychology and Offender Profiling*, 3(2), 91–103. DOI: 10.1002/jip.45.
- Canter, D. V., Youngs, D. (2008). *Applications of geographical offender profiling*. Aldershot: Ashgate Publishing.
- Chainey, S., Ratcliffe, J. (2008). *GIS and crime mapping*. Chichester: Wiley.
- Górski, M. (2021). The accuracy of geographic profiling methods based on the example of burglaries in Warsaw. *Problems of Forensic Sciences*, 125, 51–65.
- Hammond, L., Youngs, D. (2011). Decay functions and criminal spatial processes: Geographical offender profiling of volume crime. *Journal of Investigative Psychology and Offender Profiling*, 8(1), 90–102. DOI: 10.1002/jip.132.
- Levine, N. (2000). *Crimestat: A spatial statistics program for the analysis of crime incident locations* (version 1.1). Washington, DC: National Institute of Justice.
- Levine, N., Block, R. (2011). Bayesian journey-to-crime estimation: An improvement in geographic profiling methodology. *The Professional Geographer*, 63(2), 213–229. <https://doi.org/10.1080/00330124.2010.547152>.
- Lundrigan, S., Czarnomski, S., Wilson, M. (2010). Spatial and environmental consistency in serial sexual assault. *Journal of Investigative Psychology and Offender Profiling*, 7(1), 15–30. DOI: 10.1002/jip.100.
- O'Leary, M. (2011). Modeling criminal distance decay. *Cityscape*, 13(3), 161–198. Retrieved June 19, 2017 from [https://www.huduser.gov/portal/periodicals/cityscpe/vol13num3/Cityscape\\_Nov2011\\_Modelling\\_Criminal.pdf](https://www.huduser.gov/portal/periodicals/cityscpe/vol13num3/Cityscape_Nov2011_Modelling_Criminal.pdf).
- Rengert, G. F. (1996). *The geography of illegal drugs*. Boulder, CO: Westview Press.
- Rengert, G. F., Piquero, A. R., Jones, P. R. (1999). Distance decay reexamined. *Criminology*, 7(2), 427–446. DOI: 10.1111/j.1745-9125.1999.tb00492.x.
- Rich, T., Shively, M. (2004). *A methodology for evaluating geographic profiling software*. Cambridge, MA: Abt Associates Inc. Retrieved June 18, 2017 from <https://www.ncjrs.gov/pdffiles1/nij/grants/208993.pdf>.
- Rossmo, D. K. (2000). *Geographic profiling*. Boca Raton, FL: CRC Press.
- Rossmo, D. K. (2005). Geographic heuristics or shortcuts to failure? Response to Snook et al. *Applied Cognitive Psychology*, 19(5), 651–654. DOI: 10.1002/acp.1144.
- Snook, B., Taylor, P. J., Bennell, C. (2005). Shortcuts to geographic profiling success: A reply to Rossmo (2005). *Applied Cognitive Psychology*, 19(5), 655–661. DOI: 10.1002/acp.1142.
- Wickham, H. (2009). *ggplot2: Elegant Graphics for Data Analysis*. New York: Springer Verlag.

---

## Corresponding author

Michał Górski  
 College of Inter-Faculty Individual Studies in  
 Mathematics and Natural Sciences  
 University of Warsaw  
 ul. Stefana Banacha 2C  
 PL 02-097 Warszawa  
 e-mail: mgorski@student.uw.edu.pl

---

## TARGET BACKCLOTH SPRAWCY, DŁUGOŚĆ SERII I DOKŁADNOŚĆ PROFILOWANIA GEOGRAFICZNEGO

### SYMULACYJNA ANALIZA TARGET BACKCLOTH SPRAWCY, DŁUGOŚCI SERII I DOKŁADNOŚCI PROFILOWANIA GEOGRAFICZNEGO

#### Wstęp

Profilowanie geograficzne (GP) to zestaw metod skoncentrowanych na umożliwieniu organom ścigania priorytetyzacji obszaru (lub pewnego podzbioru potencjalnych podejrzanych) w oparciu o jego położenie geograficzne w stosunku do miejsc popełnienia przestępstw w ramach serii przestępstw (Rossmo, 2000; Chainey, Ratcliffe, 2008). Metody te obejmują specjalistyczne oprogramowanie komputerowe, które wskazuje konkretny obszar jako bardziej prawdopodobną lokalizację faktycznego sprawcy (Chainey, Ratcliffe, 2008). Oprogramowanie to bazuje głównie na odległości przebytej przez przestępcę i zwykle nie uwzględnia czynników środowiskowych (Chainey, Ratcliffe, 2008). Czynniki te, określane jako środowiskowe zaplecze sprawcy (*target backcloth*), są właściwościami obszaru, które są korzystne z punktu widzenia potencjalnych sprawców i wpływają na podejmowane przez nich decyzje (Brantingham, Brantingham, 1991). Istnieją wyjątki od tej reguły w przypadku oprogramowania, które zawiera więcej informacji przestrzennych, takich jak bayesowskie podejście do profilowania geograficznego wymagające nie tylko ogólnego rozkładu odległości między miejscami przestępstw a domem przestępcy (tzw. *journey-to-crime*), ale także lokalizacji przestępców, którzy wcześniej popełnili przestępstwa w najbliższym otoczeniu (Levine, Block, 2011).

Jak dowodzą Lundrigan, Czarnomski i Wilson (2010), *target backcloth* sprawcy jest pojęciem ściśle związanym z okazjami. Autorzy twierdzą, że „składają się na nie dynamiczne i niepoliczalne wymiary i cechy, które stwarzają potencjalne możliwości popełnienia przestępstwa” (s. 19). Definicja ta jest dość jasna, przy czym jednocześnie nie ogranicza charakteru ani rodzaju zmiennych, które powinny zostać uwzględnione w *target backcloth* sprawcy. Istnieje szereg badań wykazujących zmienne potencjalnie istotne dla tego czynnika. We wspomnianej analizie Lundrigan i in. (2010) dowodzą, że w seriach napaści na tle seksualnym sprawcy wybierają określone środowisko, ale – jak wspominają autorzy – ich analiza była ograniczona do zmiennych, które zostały pierwotnie zarejestrowane przez policję, a zatem niektóre istotne czynniki mogły nie zostać wzięte pod uwagę. Bernasco i Block (2009) przeprowadzili dokładniejszą analizę napadów rabunkowych w Chicago: uwzględniła ona strukturę etniczną i rasową danego obszaru, aktywność gangów, liczbę potencjalnych celów,

dane demograficzne sprawców, przebyta odległość itp. Autorzy stwierdzili, że powyższe czynniki miały wpływ na proces wyboru celu, ale najprawdopodobniej nie były to jedyne zmienne, które powinny być brane pod uwagę. Kwestia *target backcloth* sprawcy ma istotne praktyczne konsekwencje. Według Lundrigan i in. (2010) profilowanie geograficzne jest ściśle związane z tą koncepcją i ma ogromne implikacje praktyczne. Rossmo (2000) oraz Canter, Coffey, Huntley i Missen (2000) wymieniają ten czynnik jako jeden z tych, które są ściśle związane z profilowaniem geograficznym i mogą wpływać na jego dokładność. Niestety nadal nie wiadomo, w jaki sposób rozkład okazji do popełniania przestępstw wpływa na dokładność profilowania geograficznego. Istnieje wiele przyczyn, dla których dotychczas wykonano niewiele badań dotyczących tego zagadnienia.

Po pierwsze, nie opracowano dotąd metody pomiaru wpływu *target backcloth* sprawcy na dokładność profilowania geograficznego. Jak wspomniano powyżej, czynnik ten obejmuje bardzo szeroki zakres zagadnień, a to, co stanowi okoliczności sprzyjające popełnianiu przestępstw, nadal nie jest w jasny sposób określone. Zasadniczym problemem jest sprecyzowanie celów na danym obszarze. Każdy przestępca może mieć inne preferencje w ramach tego samego rodzaju przestępstwa, a zatem różne obszary będą postrzegane jako obfitujące w potencjalne cele. To w praktyce uniemożliwia określenie zakresu możliwości dla każdego obszaru, a co za tym idzie – wpływu na dokładność algorytmów profilowania geograficznego. Różnice w dokładności profilowania geograficznego na różnych obszarach mogą wynikać z rozmieszczenia celów, ale wpływ mogą mieć również inne czynniki. Mniejsza dokładność może być spowodowana większą strefą buforową, specyficzną siatką dróg, dostępnymi środkami transportu, wielkością badanego obszaru czy wreszcie samym *target backcloth* sprawcy. Jest to prawdopodobnie przyczyna dla której Snook, Taylor i Bennell (2005) zaznaczają, że istnieje bardzo niewiele dowodów na wpływ tego czynnika na profilowanie geograficzne. Rossmo (2005) podaje przekonujący przykład przestępcy polującego na prostytutki. Z racji dostępności ofiar obszar jego działalności przestępczej ograniczałby się głównie do dzielnicy czerwonych latarni, ale nie oznacza to, że ów przestępca by tam mieszkał.

W literaturze przedmiotu wyróżnia się zasadniczo dwie metody profilowania geograficznego. Pierwszą z nich jest odległość od miejsca pobytu sprawcy

(potocznie zwanego punktem zakotwiczenia, w większości przypadków jest to dom sprawcy, ale nie musi tak być; Rossmo, 2000) do punktu maksymalnego prawdopodobieństwa, określana terminem *error distance* (dystans błędu; Rich, Shively, 2004). Można ją wykorzystać do oceny prostych mierników (punkt minimalnej odległości, pierwsze albo ostatnie znane zdarzenie, średnia, itp.) i prognoz wykonanych w oparciu o oprogramowanie komputerowe (Rigel, Dagnet lub podobne). Drugą jest koszt poszukiwań (*search cost*), metoda polegająca na obliczeniu powierzchni obszaru, w którym prawdopodobieństwo znalezienia sprawcy jest większe niż w miejscu jego zamieszkania. Nieco inna metoda, zwana procentową wartością trafności (*hit percentage* lub *hit score percentage*), oblicza procentowy udział tego obszaru w całym obszarze wyszukiwania, dając szacunkową ocenę stopnia, w jakim obszar wyszukiwania może zostać zmniejszony przez profilowanie geograficzne. Metoda ta jest stosowana wyłącznie do oceny dokładności oprogramowania używanego do profilowania geograficznego i została opisana wraz z innymi w raporcie stworzonym dla Narodowego Instytutu Sprawiedliwości (*The National Institute of Justice, NIJ*) w Waszyngtonie (Rich, Shively, 2004). W odpowiedzi na powyższe sprawozdanie Rossmo (2005) argumentował, że jedyne wskaźniki pozwalające na właściwe oszacowanie dokładności profilowania geograficznego to koszt poszukiwań oraz procent trafień. Autor podał przykłady przypadków, w których kształt płaszczyzny prawdopodobieństwa był nieregularny, jednak przy ocenie za pomocą procentowego współczynnika trafności profil stawał się bardzo dokładny. Zważywszy jednak na fakt, że odległość od punktu największego prawdopodobieństwa była duża, profil ten wydawał się jednocześnie niedokładny. Przekonującym argumentem było to, że w rzeczywistości profil był dokładny, ponieważ sprawca mieszkał w jednym z bardziej prawdopodobnych obszarów, jednak gdy dokładność mierzono odległością od punktu o największym prawdopodobieństwie, nie wydawał się on dokładny. Zakłada się, że poszukując przestępcy, policja będzie rewidować wyznaczoną płaszczyznę prawdopodobieństwa i gdyby tak było naprawdę, wniosek byłby oczywiście prawdziwy. Nie wiadomo również, jak często kształt powierzchni zagrożenia jest na tyle nieregularny, że dokładność liczona za pomocą odległości od punktu maksymalnego prawdopodobieństwa daje znacząco inne wyniki niż przy zastosowaniu wskaźnika kosztu poszukiwań. Inną kwestią jest to, czy ta nieprawidłowość jest specyficzna dla algorytmu Rossmo, czy też może wystąpić przy zastosowaniu różnych wskaźników w celu uzyskania powierzchni zagrożenia.

## Liczba zdarzeń

Problem stanowi również liczba zdarzeń wykorzystywanych do oceny metod profilowania geograficznego. Rossmo (2000) twierdzi, że aby profilowanie geograficzne było dokładne, seria musi składać się z co najmniej pięciu zdarzeń, jednak tak długie serie są bardzo rzadko opisywane w literaturze. Na przykład badania Lundrigan i in. (2010), dotyczące napaści seksualnych, obejmowały 76 przestępców, przy czym 34% z nich popełniło tylko dwa przestępstwa, 28% trzy, a tylko 23% od pięciu do czternastu przestępstw. Średnia długość serii wynosiła 3,8, a mediana – trzy przestępstwa. Fakt, że przestępstwa były dokonywane w latach 1970–2002, pokazuje, jak trudno jest zebrać odpowiednią liczbę danych. Badania te nie byłyby jednak przydatne do określenia, z ilu przestępstw powinny składać się serie, aby można było stosować algorytmy profilowania geograficznego. Jest to najprawdopodobniej powód, dla którego Rossmo (2000) wykorzystał symulację komputerową do oszacowania minimalnej długości serii. Dzięki temu można było generować serie o dowolnej długości. Metoda ta została skrytykowana przez Snooka i in. (2005), którzy twierdzili, że symulacja ta nadmiernie upraszcza proces typowania celów (ofiar) przez sprawców. Algorytm generujący serie wybierał losową lokalizację w pobliżu domu sprawcy, wykorzystując funkcję oporu przestrzeni (Snook i in., 2005). Argumentowano, że w tym modelu było oczywiste, że w miarę rozwoju serii wartości będą koncentrować się na miejscu zamieszkania sprawcy. Z drugiej strony symulacja, którą przeprowadził Rossmo, miała prawdopodobnie na celu zilustrowanie dokładności w optymalnych warunkach i wykazanie, że w rzeczywistych sytuacjach życiowych może być potrzebna dłuższa seria. Chociaż nie określono optymalnej długości serii, jest to w zgodzie ze stwierdzeniem tego autora, że używanie krótszych serii do testowania profilowania geograficznego może prowadzić do fałszywych wniosków. Inne podejście zostało zastosowane przez Levine'a i in. (2000), którzy podzielili próbę przestępstw seryjnych na trzy grupy: pierwsza to serie o długości od trzech do pięciu, druga sześć do dziewięciu, a trzecia dziesięć i więcej przestępstw. Chociaż autorzy byli w stanie wykazać poprawę wraz z długością serii, konstrukcja tego badania nie pozwala na dokładne określenie jej preferowanej długości. Wciąż jednak długość serii pozostaje jedną z głównych cech przestępstw seryjnych wpływających na dokładność profilowania geograficznego. Często trudno jest dysponować odpowiednio dużą próbą z długimi seriami zdarzeń, która pozwoliłaby na ocenę dokładności dla tego typu przestępstw. Dobry przykład stanowią tu badania Górskiego (2021), gdzie wystarczającą dokładność predykcji dla próby testowej uzyskano dla dłuższych serii przestępstw. Oznaczałoby to, że trudno jest oszacować, kiedy seria przestępstw jest wystarczająco

długa, aby można było zastosować oprogramowanie do profilowania geograficznego lub aby było ono znacząco pomocne.

### Rozkład dyskretny lub ciągły

Istnieje jeszcze jeden powód, dla którego model zastosowany przez Rossmo (2000) może nie tworzyć dokładnej symulacji zachowań przestępców. Nawet przy założeniu równomiernego rozmieszczenia celów na całym obszarze działania sprawcy nie ma gwarancji, że będą miały one rozkład ciągły. Rozkład ciągły oznaczałby nie tylko to, że cele są równomiernie rozmieszczone na danym obszarze, ale również, że przestępca może wybrać dowolne miejsce w dowolnej odległości od swojego miejsca zamieszkania, aby popełnić przestępstwo. Może to być prawdą w przypadku napadów ulicznych (choć wciąż jest to wątpliwe), ale jeśli weźmie się pod uwagę włamanie, to oczywiście tak nie jest. Dobrym przykładem może być przypadek, w którym przestępca wybiera sobie za cel małe sklepy w dzielnicy mieszkalnej. Sklepy są zazwyczaj równomiernie rozmieszczone wokół nieruchomości mieszkalnych, ale sprawca nadal byłby ograniczony do punktów, w których znajdują się sklepy. W rzeczywistości, zdaniem autora, właściwy jest jedynie rozkład dyskretny, a cele na omawianym obszarze są zawsze zlokalizowane w określonych punktach, a nie w sposób ciągły. Teza ta jest dodatkowo wspierana przez badania nad sposobami wyboru celów, w których autorzy wykorzystują dyskretne rozkłady prawdopodobieństwa do opisu przestrzennych zachowań sprawców (np. Bernasco, Block, 2009). Można zaryzykować twierdzenie, że najprawdopodobniej rozkład ciągły nie miał wpływu na wyniki dotyczące liczby przestępstw potrzebnych do zastosowania profilowania geograficznego. Należy jednak rozważyć konsekwencje zastosowania dyskretnego rozkładu prawdopodobieństwa. Na przykład może ono silnie wpłynąć na efekty działania strefy buforowej. Strefa buforowa to koncepcja, zgodnie z którą przestępcy decydują się na popełnianie przestępstw w większej odległości od domu, aby uniknąć rozpoznania, a w konsekwencji ujęcia. Obszar wokół miejsca zamieszkania sprawcy (lub ogólniej – wokół jego punktu zakotwiczenia), w którym powstrzymuje się on od popełniania przestępstw ze względu na możliwość rozpoznania, nazywamy strefą buforową. Jeśli odległość, jaką sprawca musi pokonać do najbliższego możliwego celu, jest większa niż strefa buforowa, to strefa buforowa nie będzie miała wpływu na rozmieszczenie przestępstw. Podobny argument podnoszą Canter i Youngs (2008), którzy wspominają, że strefa buforowa może nie być widoczna, gdy sprawca wybiera konkretny cel. Należy wziąć pod uwagę dodatkową możliwość, że w przypadku specyficznych sytuacji sprawca może nie musieć szukać konkretnego

celu. Efekt przypisywany strefie buforowej może być widoczny, jeżeli przeciętnie sprawca musi pokonać pewną odległość do znalezienia się w pierwszej sprzyjającej sytuacji. W przykładzie sprawcy atakującego małe sklepy – jeśli średnio odległość uznawana przez sprawców za bezpieczną do popełnienia przestępstwa (strefa buforowa) byłaby znacznie mniejsza niż średnia odległość do pierwszego dostępnego celu, sama strefa buforowa nie miałaby widocznego wpływu na wybór celu. Jednak przy rozpatrywaniu rozkładu pokonanej przez sprawców odległości widzielibyśmy coś, co można by interpretować jako strefę buforową, ale co nie miałoby nic wspólnego z rzeczywistą strefą buforową. Scenariusz, w którym przestępca musi pokonać pewną odległość do znalezienia się w sytuacji sprzyjającej do popełniania przestępstwa jest bardziej prawdopodobny niż mogłoby się wydawać. Wynika to z faktu, że rozpatrując *journey-to-crime* (odległość pomiędzy punktem zakotwiczenia sprawcy a miejscem popełnienia przestępstwa), posługujemy się jednowymiarowym rozkładem prawdopodobieństwa, natomiast gdy rozpatrujemy cały obszar, mamy do czynienia z dwuwymiarowym rozkładem prawdopodobieństwa. Efekt ten dobrze opisuje O’Leary (2011), który pokazuje, że rozkład jednowymiarowy ze strefą buforową nie musi oznaczać, że przy rozpatrywaniu rozkładu dwuwymiarowego nadal będzie widoczna strefa buforowa.

Rozważmy trzy obszary: jeden okrąg w odległości do jednego kilometra od domu sprawcy, drugi okrąg wokół domu w odległości od jednego do dwóch kilometrów oraz trzeci okrąg w odległości od dwóch do trzech kilometrów. Powierzchnia każdego z nich wynosi odpowiednio  $\pi$  km<sup>2</sup>,  $3\pi$  km<sup>2</sup> oraz  $5\pi$  km<sup>2</sup>. Oznacza to, że w drugim obszarze jest prawdopodobnie trzy razy więcej możliwości niż w pierwszym (zakładając równomierny rozkład możliwości); jednak w trzecim obszarze jest mniej niż dwa razy więcej okazji do popełniania przestępstwa niż w drugim. Wskazuje to, że mniejsza liczba przestępstw popełnianych bliżej miejsca zamieszkania sprawcy może wynikać raczej z liczby możliwości popełnienia przestępstwa w innym miejscu niż z niechęci sprawcy do popełniania przestępstw w pobliżu miejsca zamieszkania. Przykład ten pokazuje również, że w bliskiej odległości od domu przestępca następuje duży wzrost liczby sprzyjających okazji, który będzie się zmniejszał wraz z odległością. Jak wyjaśniają Rengert, Piquero i Jones (1999), liczba przestępstw powinna początkowo wzrastać wraz z odległością od miejsca zamieszkania sprawcy, a następnie po pewnym czasie zacząć maleć. Ten punkt ma być strefą buforową, ale – jak opisano powyżej – jest to dokładnie ten sam efekt, którego powinniśmy się spodziewać w modelu bez strefy buforowej, ale z dyskretnym rozkładem celów. Inny argument na rzecz strefy buforowej został przedstawiony przez Cantera i Larkina (1993). Rozważając regresję liniową pomiędzy maksymalną odległością pomiędzy przestępstwami a maksymalną

odległością *journey-to-crime* (równanie regresji było następujące:  $y = 0.84 \times x + 0.61$ ), należy zwrócić uwagę, że stała w równaniu regresji (0,61 mili) była mniejsza niż średnia minimalna odległość przebyta przez przestępców (1,53 mili). Autorzy doszli do wniosku, że strefa buforowa była odpowiedzialna za to, że średnio pokonywana minimalna odległość była ponad dwa razy większa niż przewidywana maksymalna.

## Cel badań

Celem niniejszej pracy było ustalenie minimalnej długości serii, która pozwala na zastosowanie profilowania geograficznego. Jak już wspomniano, metoda, którą zaproponował Rossmo (2000), nie jest pozbawiona wad i być może konieczne byłoby nowe podejście do niniejszego zagadnienia. Nowa technologia, oprogramowanie GIS, może umożliwić wykorzystanie bardziej złożonych modeli, które pozwoliłyby na uwzględnienie większej liczby czynników. Ponieważ, jak już wspomniano, zebranie odpowiednio dużej próby długich serii przestępstw jest prawie niemożliwe, wybrano metodę symulacji. Dzięki zastosowaniu symulacji uniknięto także innych czynników, które mogłyby wpłynąć na wyniki. Były to: istnienie punktów zaczepienia innych niż miejsce zamieszkania przestępcy oraz wadliwa analiza powiązań. W modelu, który zastosował Rossmo (2000), wprowadzono pewne modyfikacje w celu ustalenia minimalnej liczby przestępstw niezbędnych do zastosowania profilowania geograficznego. Objęły one dwa czynniki: nieciągły, dyskretny rozkład okazji do popełnienia przestępstwa w danym rejonie oraz *target backcloth* sprawcy – czynnik ten wzięto pod uwagę, ponieważ był to element, którego brakowało w oryginalnych badaniach, a uwzględnienie go pozwoliło na analizę nierównomiernie rozłożonych okazji do popełnienia przestępstwa. Aby zrealizować ten cel, symulację przeprowadzono na dwa różne sposoby: pierwszy z nich to próba losowa, w której możliwe lokalizacje przestępstw są rozłożone na obszarze z jednakowym prawdopodobieństwem; drugi jest zgodny z rzeczywistymi lokalizacjami faktycznych włamań – okazje znajdują się więc nie tylko w określonych punktach, ale są również skupione – tak jak w rzeczywistych scenariuszach. Z tych dwóch zestawów punktów, jednego losowego, drugiego opartego na rzeczywistych lokalizacjach, utworzono sztuczne serie przestępstw. Do opisu właściwości modelu wykorzystano wskaźniki powszechnie stosowane w badaniach nad zachowaniami przestrzennymi przestępców. Należą do nich minimalna i maksymalna odległość od miejsca popełnienia przestępstwa (*journey-to-crime*), maksymalna odległość między miejscami popełnienia przestępstwa (maksymalna odległość między miejscami popełnienia przestępstwa w serii) oraz liczba sprawców stabilnych (*marauders*)

i mobilnych (*commuters*) w próbie. W modelu nie uwzględniono strefy buforowej, ale pomimo tego w obu grupach o ustalonych warunkach spodziewano się wyników zbliżonych do efektu opisanego przez Cantera i Larkina (1993), przypisywanego strefie buforowej. Przewidywano również, że ze względu na dyskretny rozkład okazji do popełnienia przestępstwa zmniejszy się liczba bardzo krótkich podróży odbywanych przez sprawców.

Drugim celem było zbadanie zależności pomiędzy długością serii a dokładnością profilowania geograficznego w zależności od dwóch grup warunków symulacji. Spodziewano się, że w grupie nieuwzględniającej *target backcloth* sprawcy przy dłuższych seriach oba pomiary będą wykazywać zwiększoną dokładność, podczas gdy w grupie biorącej pod uwagę ów czynnik ten wzrost może być mniejszy lub nawet w pewnym momencie ulec zatrzymaniu. W związku z tym oczekiwano, że w przypadku grupy uwzględniającej *target backcloth* sprawcy dłuższe serie będą konieczne do uzyskania podobnej dokładności jak w grupie nieuwzględniającej zarówno tego czynnika, jak i długości serii pięciu przestępstw. Ponieważ nie prowadzono badań na temat jego wpływu na profilowanie geograficzne i długość serii, nie było jasne, jak dokładnie długie powinny być te serie.

## Metoda

Dla celów niniejszego badania z pomocą polskiej policji uzyskano lokalizacje dla 6 115 włamań w Warszawie i okolicach. Z próby tej nie wyodrębniono żadnej podgrupy, przy czym założono, że miejsca popełnienia przestępstw odpowiadają ogólnemu rozkładowi potencjalnych celów. Przy okazji, w związku z tym, że przedmiotem zainteresowania nie byli prawdziwi przestępcy, uniknięto problemu wynikającego z faktu, że przestępcy mogliby mieć te same preferencje (Bernasco, 2009). Ten hipotetyczny model pozwolił również na uniknięcie rozważania problemu, na czym polega dogodna lokalizacja dla danego przestępcy, a także na skupienie się wyłącznie na wpływie *target backcloth* sprawcy i rozkładzie potencjalnych celów. Ta sama liczba fikcyjnych przestępstw została wylosowana z tego samego obszaru. Do opisu różnic pomiędzy dwoma grupami założonych warunków wykorzystano metodę analizy hotspotów opisaną przez Chaineya i Ratcliffe'a (2008), czyli odległość do najbliższego sąsiada. W przypadku próby opartej na rzeczywistych zdarzeniach oczekiwano, że przestępstwa będą wykazywały mniejszą odległość do najbliższego sąsiada, a jednocześnie większą odległość maksymalną. Dla próbki losowej rozkład ten miałby być bardziej podobny do rozkładu normalnego – z mniejszym maksimum, ale większą średnią i medianą. Lokalizacje domów przestępców były generowane losowo, przy czym obszar, z którego można było je wybrać, był ograniczony



do 64% obejmujących centrum oryginalnej powierzchni. Zostało to ustalone w taki sposób, aby miejsca zamieszkania przestępców znajdowały się w pewnej odległości od granicy obszaru, miało to na celu zminimalizowanie wpływu sprawców mających okazję do popełniania przestępstw tylko w jednym kierunku od swojego miejsca zamieszkania. Dla każdego z przestępców obliczono wagi dla każdego z możliwych miejsc popełnienia przestępstwa. Dla próby losowej były to losowe lokalizacje, w warunkach symulujących (uwzględniających) możliwy wpływ środowiska były to prawdziwe miejsca zdarzeń. Do wygenerowania serii wybrano funkcję wykładniczą, gdyż jest to jedna z najczęściej wykorzystywanych funkcji w badaniach nad *journey-to-crime*, a jednocześnie wykorzystuje się ją do tworzenia funkcji rozkładu odległości również w badaniach nad profilowaniem geograficznym. Ponadto funkcja ta nie uwzględnia strefy buforowej, więc gdyby taka istniała, to wynikałaby wyłącznie z rozkładu celów. W przypadku *journey-to-crime* starano się zachować rozkład wykładniczy, dlatego przy obliczaniu wag należało dokonać niewielkiej modyfikacji. Wynika to ponownie z różnicy w przypadku dwu- i jednowymiarowego rozkładu prawdopodobieństwa dla odległości między miejscami przestępstw a domem przestępcy (*journey-to-crime*). Dla zdarzenia  $i$  w odległości  $d_i$  od miejsca zamieszkania sprawcy obliczono wagi  $x_i$  na podstawie następującego wzoru:

$$x_i = \exp(-A * d_i) / d_i$$

Następnie wszystkie wagi zostały podzielone przez ich sumę dla konkretnego przestępcy. W kolejnym kroku z całej próby przestępstw wybrano określoną liczbę przestępstw (długość serii) w oparciu o wyliczone wagi. Podział funkcji wykładniczej ze względu na odległość wynikał z przejścia z rozkładu dwuwymiarowego do jednowymiarowego (por. O'Leary, 2011). Dla każdej z grup warunków sprawdzono, czy rozkład *journey-to-crime* był statystycznie różny od rozkładu wykładniczego. Wszystkie obliczenia wykonano w programie R w wersji 3.3.3, wykresy wykonano przy użyciu biblioteki ggplot (Wickham, 2009).

## Wartość stałej

Wartość stałej  $A$  w podanym wzorze nie została oszacowana empirycznie. Ponieważ stała ta określa znaczenie odległości w modelu, kluczowe było przetestowanie jak największej liczby akceptowalnych wartości, aby przeanalizować zachowanie modelu w różnych warunkach, w których *target backcloth* sprawcy ma większy lub mniejszy wpływ. W przypadku większego  $A$  różnica w wadze pomiędzy możliwymi celami byłaby większa, reprezentując w ten sposób sprawców, którzy wybierają cele na podstawie ich bliskiej odległości. Mniejsza stała

oznaczałaby, że cele są wybierane bardziej losowo, a zatem miejsca sprzyjające popełnianiu przestępstw są bardziej prawdopodobne, ponieważ prawdopodobieństwo obszaru byłoby zbliżone do rozkładu okazji do popełniania przestępstw. Aby przetestować model w różnych okolicznościach, opisano wyniki dla dwóch wartości. Podsumowując – przebadano 90 różnych długości serii i różne wartości stałej. Ze względu na ograniczoną objętość artykułu oraz dla zachowania przejrzystości większość wyników zostanie przedstawiona dla stałej wartości  $A$  równej 0,234174, która jest oparta na badaniach Hammond i Youngs (2011) dotyczących seryjnych włamywaczy. W niektórych przypadkach wyniki zostaną porównane z tymi uzyskanymi przy  $A$  równym 0,04574 (uzyskany przez Cantera i Hammond, 2006). Analizując wpływ *target backcloth* sprawcy na strefę buforową, wybrano serię o długości trzech zdarzeń. Jest to znacznie mniej niż oczekiwana przez Rossmo (2000) minimalna długość serii, ale, jak opisano powyżej, dłuższe serie są rzadko opisywane w literaturze, a celem było odniesienie uzyskanych wyników do efektów obserwowanych w innych badaniach. Wyjątkiem będzie analiza wpływu długości serii na dokładność, gdzie wyniki będą przedstawione dla wszystkich testowanych długości serii. W celach porównawczych wykorzystano wyniki uzyskane dla serii składających się z pięciu incydentów i losowego rozkładu celów, gdyż są to warunki najbardziej zbliżone do tych, które zastosował Rossmo (2000). Własności modelu dla różnych wartości, a także funkcje generujące próbki mogą zostać udostępnione na życzenie.

## Uzyskane wyniki

Aby wykazać różnice pomiędzy próbkami przestępstw losowych i rzeczywistych, w pierwszej kolejności przeanalizowano rozkład odległości do najbliższego sąsiada. Dla warunków losowych maksymalna wartość wynosiła 0,72, a minimalna 0,0063. Te same wartości dla przestępstw rzeczywistych wynosiły odpowiednio 2,46 i 0,0007. Średnia wyniosła 0,14 dla *target backcloth* sprawcy (mediana = 0,09) oraz 0,23 dla przestępstw losowych (mediana = 0,22). Rozkład odległości najbliższego sąsiada został przedstawiony na rycinie 1.

## Strefa buforowa

Aby sprawdzić, czy wystąpił efekt zwykle przypisywany strefie buforowej, średnia minimalnej odległości do przestępstwa została porównana ze stałą w regresji liniowej pomiędzy maksymalną odległością pomiędzy przestępstwami a maksymalną odległością pomiędzy miejscami przestępstw a domem przestępcy (*journey-to-crime*). Dla  $A$  równego 0,234174 i długości serii wynoszącej trzy zdarzenia funkcja regresji otrzymała wzór

$y = 0,85 \times x + 0,91$ , natomiast średnia minimalna *journey-to-crime* wyniosła 1,86. Dla losowego rozkładu okazji do popełnienia przestępstwa zaobserwowano podobny efekt: przy funkcji regresji:  $y = 0,76 \times x + 0,48$  średnia minimalna odległość wyniosła 1,28. Ponadto zbadano rozkład podróży do przestępstwa za pomocą testu Kołmogorowa-Smirnowa i stwierdzono istotną statystycznie różnicę pomiędzy próbą a rozkładem wykładniczym dla *target backcloth* sprawcy ( $D = 0,1$ ,  $p < 0,01$ ), natomiast różnica taka nie występowała dla losowego rozkładu przestępstw ( $D = 0,05$ ). Rozkład zdarzeń dla obu warunków przedstawiono na rycinie 2. Należy zauważyć, że dla innych wartości A widoczny był podobny efekt, a stała w funkcji regresji liniowej była większa od średniej minimalnej odległości pokonanej przez sprawców tylko osiem razy na 90 badanych przypadków. Jednakże dla dłuższych szeregów stała w regresji liniowej była często ujemna. Ponadto obliczono maksima dla estymacji jądrowej funkcji gęstości, które wyniosły 1,58 dla *target backcloth* sprawcy i 1,32 dla warunków losowych. Wartości te są znacząco wyższe niż średnia odległość między miejscami popełnienia przestępstwa (0,14 dla *target backcloth* sprawcy i 0,23 dla warunków losowych). Średnia *journey-to-crime* wynosiła 4,69 (mediana 3,74) dla *target backcloth* sprawcy i 3,8 (mediana 2,88) dla warunków losowych.

W celu sprawdzenia spójności otrzymanych wyników dla serii o długości 3 zdarzeń i A równym 0,234174 test powtórzono dziesięć tysięcy razy. Badanie przeprowadzono tylko dla *target backcloth* sprawcy, wyniki przedstawiono na rycinie 3. Tylko w siedmiu przypadkach na dziesięć tysięcy stała była większa od średniego minimalnego *journey-to-crime*, średnia wartość stałej wynosiła 0,99, natomiast średnia (ze średnich minimów) *journey-to-crime* to 2,13.

### Dokładność profilowania geograficznego

Na potrzeby niniejszego badania zastosowano dwie metody obliczania dokładności. Jedną z nich była odległość punktu o największym prawdopodobieństwie do faktycznego miejsca zamieszkania sprawcy (*error distance*), drugą procent trafień (*hit score percentage*). Na rycinach 4 i 5 pokazano, jak zmieniają się te pomiary w zależności od długości serii. Do stworzenia ryc. 4 posłużono się wskaźnikiem *error distance* jako miarą dokładności. Jak można zaobserwować, w przypadku *target backcloth* sprawcy nie występuje znacząca poprawa dla serii dłuższych niż trzy zdarzenia.

Aby sprawdzić, czy tak jest w rzeczywistości, przeprowadzono test Kruskala-Wallisa. W teście tym dla danej długości serii uwzględniono wszystkie serie przestępstw, które były równie długie lub dłuższe. Badane grupy składały się z serii o jednakowej długości. Test wykonano dla serii uwzględniających i nieuwzględniających *target*

*backcloth* sprawcy. Punkt, w którym nie było statystycznej różnicy między grupami, został przyjęty jako punkt, w którym dłuższe serie nie poprawiały dokładności mierzonej odległością od punktu maksymalnego prawdopodobieństwa. Wyniki przedstawiono w tabeli 1.

Ryc. 5 opracowano w ten sam sposób, na podstawie tej samej próbki, przy czym dokładność profilu została ustalona na podstawie procentu trafień. Widoczny jest wzrost dokładności wraz z długością serii dla obu grup ustalonych warunków (losowego i z uwzględnieniem *target backcloth* sprawcy), choć lepszą dokładność uzyskuje się zawsze w warunkach losowych.

W celu otrzymania odpowiedzi na pytanie: jak długa powinna być seria wykroczeń w przypadku uwzględnienia *target backcloth* sprawcy, aby uzyskać dokładność zbliżoną dla otrzymanej dla losowego rozkładu szans i serii o długości pięciu zdarzeń, każda długość serii została porównana z serią pięciu zdarzeń w warunkach losowego rozkładu na podstawie wskaźnika procentu trafień. Ten sposób pomiaru dokładności został wybrany ze względu na metodykę stosowaną przez Rossmo (2000), a także ze względu na wcześniejsze wyniki, czyli brak poprawy dokładności wraz z długością serii przy zastosowaniu wskaźnika *error distance*. Rozkład dokładności porównywano za pomocą testu Kołmogorowa-Smirnowa oraz testu Wilcoxona. Oba nie wykazały znaczących różnic w dokładności pomiędzy *target backcloth* sprawcy dla serii o długości dziewięciu zdarzeń a losową próbą przestępstw dla serii o długości pięciu zdarzeń. Podobne wyniki uzyskano dla różnych analizowanych wartości stałej A. Wartości dla obu statystyk zostały przedstawione w tabeli 2.

Aby sprawdzić stabilność dokładności liczonej jako procent trafień, przeprowadzono taką samą metodę jak w przypadku pomiaru odległości do punktu maksymalnego. Ponownie zastosowano test Kruskala-Wallisa. Wyniki dla obu metod testowania dokładności zaprezentowano w tabeli 1.

Test końcowy został przeprowadzony w celu sprawdzenia, czy istnieją jakiegokolwiek różnice w dokładności pomiędzy wszystkimi testowanymi długościami serii dla obu ustalonych grup warunków. Aby tego dokonać, zastosowano dwa zestawy testów: test Kołmogorowa-Smirnowa oraz test Wilcoxona dla par obserwacji. Wyniki przedstawiono w tabeli 3.

### Omówienie wyników

Stwierdzono, że przy zastosowaniu opisanego modelu wyraźnie widoczny jest efekt podobny do strefy buforowej. Zaskakujące było to, że uzyskano go dla obu grup ustalonych warunków, co pokazuje, że dyskretny rozkład okazji do popełnienia przestępstwa jest wystarczający, aby wyjaśnić, dlaczego średnia minimalna

odległość *journey-to-crime* jest znacznie wyższa niż stała w regresji liniowej. Oznacza to, że nie jest konieczne, by okazje do popełnienia przestępstwa były skupione w określonych obszarach, tak aby mogły wpłynąć na funkcję rozkładu odległości; wystarczy równomierny, ale dyskretny rozkład celów. Badanie powtórzono 10 tys. razy dla *target backcloth* sprawy, a uzyskane wyniki wskazują, że uzyskana różnica pomiędzy minimalnym *journey-to-crime* a stałą w równaniu regresji liniowej nie jest przypadkowa. Podobnie w przypadku obu grup warunków – grupy losowej i *target backcloth* sprawy – widoczny jest spadek liczby przestępstw w bliskiej odległości od miejsca zamieszkania sprawcy. Tak więc kolejnym argumentem na potwierdzenie istnienia strefy buforowej może być wynik dyskretnego rozkładu celów. Na ryc. 2 widać, że obie grupy wykazują zachowania przypisane do strefy buforowej. Ponieważ w modelu bez strefy buforowej średnia odległość między przestępstwami wynosiła odpowiednio 0,14 i 0,23 dla *target backcloth* sprawy i dla losowej próby, można było założyć, że odległość między przestępstwami będzie o połowę mniejsza. Wyniki pokazują coś znacząco innego: średnia *journey-to-crime*, średnia minimalna *journey-to-crime* i położenie maksimum estymacji jądrowej funkcji gęstości były znacznie większe niż ta wartość. Nie dowodzi to, że strefa buforowa nie istnieje, a jedynie, że istnieją inne wytłumaczenia dla tego typu wyników. Ponadto, jak opisują Canter i Youngs (2008), istnieje możliwość, że samotni przestępcy starają się unikać popełniania przestępstw w pobliżu swoich domów, więc model ze strefą buforową może być w ich przypadku odpowiedni.

Kolejny ważny wynik dotyczy pomiarów dokładności algorytmów profilowania geograficznego. Jak widać na rycinach 4 i 5 oraz w tabelach 1 i 2, procent trafień jest bardziej czułym wskaźnikiem, który częściej wykazuje różnice między grupą losową i uwzględniającą *target backcloth* sprawy. Wykazano również większe zmiany w dokładności wraz ze wzrostem długości serii. Potwierdza to argument, którym posłużył się Rossmo (2005) w odpowiedzi na raport Narodowego Instytutu Sprawiedliwości (NIJ), że parametr *error distance* nie jest wystarczający, aby wykazać dokładność profilu geograficznego. Wraz ze wzrostem długości serii systematycznie wzrastała celność mierzona procentem trafień, natomiast efekt taki nie miał miejsca w przypadku pomiaru *error distance*. W warunkach *target backcloth* sprawy nie zaobserwowano statystycznie istotnej poprawy w zakresie *error distance* dla serii o długości trzech zdarzeń. Należy zauważyć, że w obecnym teście nie wykorzystano wzoru Rossmo, lecz zastosowano funkcję wykładniczą, a zatem efekt ten nie jest ograniczony do algorytmu profilowania geograficznego Rossmo. Snook i in. (2005) twierdzą, że parametr *error distance* pozwala na porównanie przewidywań dokonanych przez człowieka z wynikami komputerowymi, co nie jest możliwe w przypadku procentu

trafień lub podobnych wskaźników. Nie jest to jednak prawdą, jeśli punkt sugerowany przez człowieka jako punkt początkowy poszukiwań, które byłyby prowadzone w każdym kierunku aż do odnalezienia sprawcy, jest równy powierzchni okręgu o promieniu równym *error distance*. W wyniku przeprowadzonego badania proponuje się zrezygnować ze stosowania *error distance* jako miary dokładności profilowania geograficznego.

Ponadto uzyskane wyniki potwierdzają inną wypowiedź Rossmo, w której podkreśla on znaczenie *target backcloth* sprawy dla dokładności profilowania geograficznego. W prezentowanej symulacji w warunkach *target backcloth* sprawy konieczne były znacznie dłuższe serie, aby uzyskać wyniki zbliżone do tych otrzymanych w przypadku warunków losowych dla serii pięciu zdarzeń. W przypadku *target backcloth* sprawy konieczne było posiadanie co najmniej dziewięciu lokalizacji, aby uzyskać dokładność podobną do otrzymanej dla grupy losowej i serii pięciu przestępstw. Należy zauważyć, że gdy  $A$  było równe 0,04574, do uzyskania podobnych wyników potrzeba było aż 17 zdarzeń. Pokazuje to, że w warunkach rzeczywistych do uzyskania zadowalających wyników może być konieczna nawet większa liczba zdarzeń. Jest to bardzo ważny wynik, gdyż pokazuje, że długość serii może być jednym z najważniejszych czynników przy rozważaniu zastosowania profilowania geograficznego w konkretnych przypadkach. Wynik ten jest również spójny z wynikami uzyskanymi przez Górskiego (2021) na próbie polskich sprawców przestępstw. Co więcej, jak pokazano w tabeli 3, w prawie wszystkich badanych długościach serii i w obu stosowanych pomiarach dokładności wystąpiły istotne różnice między grupami, wskazujące na możliwy wpływ *target backcloth* sprawy na profilowanie geograficzne.

Istotne jest również to, że wbrew oczekiwaniom nie osiągnięto wartości progowych dla *target backcloth* sprawy przy zastosowaniu procentowej metody pomiaru trafności. Odwrotny efekt uzyskano przy zastosowaniu parametru *error distance*. W przypadku tego pomiaru dokładność profilu uwzględniającego *target backcloth* sprawy była znacznie ograniczona i nie wykazywała poprawy przy dłuższych seriach. Po dokładniejszej analizie wielu wygenerowanych profili stwierdzono, że przy zastosowaniu *target backcloth* sprawy uzyskuje się znacznie odmienny wzorzec przestrzenny. Porównując wyniki z modelem stworzonym przez Rengerta (1996), odkryto, że dla warunków losowych wyniki rzeczywiście przypominają to, co autor określił jako *distance bias* (tendencja odległościowa, która grupuje przestępstwa w pobliżu miejsca zamieszkania przestępcy). W przypadku *target backcloth* sprawy uzyskano rozkład bimodalny lub kierunkowy (tzw. *teardrop*). Oznacza to, że albo istnieje odrębny obszar wtórny o wyższym prawdopodobieństwie (w którym znajduje się miejsce zamieszkania sprawcy), albo też w jednym kierunku od punktu maksymalnego

prawdopodobieństwa prawdopodobieństwo znalezienia sprawcy maleje znacznie wolniej niż w kierunku przeciwnym. Powoduje to, że miejsce zamieszkania sprawcy znajduje się w znacznie większej odległości od punktu maksymalnego prawdopodobieństwa, pozostając jednocześnie w obszarze wysokiego prawdopodobieństwa. Oczywiście nie wiadomo, jak często może się to zdarzyć w prawdziwym życiu, ale nadal podkreśla to istotne niedogodności związane z używaniem parametru *error distance* w pomiarach dokładności. To z kolei może mieć istotne znaczenie przy analizie dotyczącej tego, jaki rodzaj metody profilowania geograficznego jest najlepszy dla danej próby przestępców. Wyniki pokazują, że procentowy wynik trafień jest lepszym narzędziem oceny i powinien być preferowany przy poszukiwaniu najlepszego algorytmu lub oprogramowania dla profilowania geograficznego.

Ponieważ obecna analiza oparta jest na symulacji komputerowej, istnieje oczywiście potrzeba dalszych badań. Mimo to niektóre wnioski z przeprowadzonych badań wydają się uniwersalne i, przynajmniej w pewnym stopniu, możliwe do zastosowania w odniesieniu do rzeczywistych sprawców przestępstw. Przede wszystkim wykazano, że dość łatwo jest uzyskać efekt podobny do strefy buforowej w modelu, który sam w sobie jej nie zawiera. Chociaż nie da się na tej podstawie stwierdzić, że strefa buforowa może nie istnieć, wskazuje to na potrzebę opracowania nowych narzędzi w poszukiwaniu tego efektu. Przy zastosowaniu pomiarów dokładności profilowania geograficznego wykazano, że *error distance* nie pozwala zmierzyć różnicy w dokładności dla różnych długości serii. Procent trafień w tych samych warunkach wykazywał stały wzrost dokładności. Wskazuje to, że nie jest on zatem odpowiednim wskaźnikiem do porównywania metod profilowania geograficznego. Chociaż wyniki nie mogą pokazać, jak powszechne może to być w prawdziwym życiu, sam fakt, że dokładność *error distance* była taka sama dla serii o długości trzech i więcej zdarzeń przy uwzględnianiu *target backcloth* sprawcy, jest uderzający. Jest to dowód na to, że parametr ten jest dalece niedoskonałą metodą pomiaru dokładności i nie powinien być stosowany.

Podsumowując: uzyskane wyniki wskazują, że granica pięciu przestępstw na serię jest zbyt niska i że dla profilowania geograficznego należy ustalić wyższy, być może nawet ponad trzykrotnie, próg. Dla wyboru metody profilowania geograficznego procent trafień wydaje się lepszą metodą oceny, ponieważ jest bardziej czuły i zdolny do pomiaru bardziej subtelnych różnic między profilami. W rozważaniach teoretycznych stwierdzono, że większość efektów przypisywanych strefie buforowej może być w rzeczywistości wynikiem dyskretnego rozkładu potencjalnych celów, a zatem mogą być potrzebne nowe metody w zakresie znajdowania takiej strefy buforowej i udowodnienia jej istnienia.