

Haake, Daniel

**Article**

## Prognose von Wohnungseinbrüchen mithilfe von Machine-Learning-Algorithmen

WISTA – Wirtschaft und Statistik

**Provided in Cooperation with:**

Statistisches Bundesamt (Destatis), Wiesbaden

*Suggested Citation:* Haake, Daniel (2021) : Prognose von Wohnungseinbrüchen mithilfe von Machine-Learning-Algorithmen, WISTA – Wirtschaft und Statistik, ISSN 1619-2907, Statistisches Bundesamt (Destatis), Wiesbaden, Vol. 73, Iss. 2, pp. 59-71

This Version is available at:

<https://hdl.handle.net/10419/233567>

**Standard-Nutzungsbedingungen:**

Die Dokumente auf EconStor dürfen zu eigenen wissenschaftlichen Zwecken und zum Privatgebrauch gespeichert und kopiert werden.

Sie dürfen die Dokumente nicht für öffentliche oder kommerzielle Zwecke vervielfältigen, öffentlich ausstellen, öffentlich zugänglich machen, vertreiben oder anderweitig nutzen.

Sofern die Verfasser die Dokumente unter Open-Content-Lizenzen (insbesondere CC-Lizenzen) zur Verfügung gestellt haben sollten, gelten abweichend von diesen Nutzungsbedingungen die in der dort genannten Lizenz gewährten Nutzungsrechte.

**Terms of use:**

*Documents in EconStor may be saved and copied for your personal and scholarly purposes.*

*You are not to copy documents for public or commercial purposes, to exhibit the documents publicly, to make them publicly available on the internet, or to distribute or otherwise use the documents in public.*

*If the documents have been made available under an Open Content Licence (especially Creative Commons Licences), you may exercise further usage rights as specified in the indicated licence.*

# PROGNOSE VON WOHNUNGS- EINBRÜCHEN MIT HILFE VON MACHINE-LEARNING-ALGORITHMEN

Daniel Haake

↳ **Schlüsselwörter:** Nachfolgedelikt – Wohnungseinbruchdiebstahl – Data Science – Machine-Learning – Tatzeitraum – kriminalgeografischer Raum

## ZUSAMMENFASSUNG

Kann man mit Machine-Learning-Algorithmen prognostizieren, ob es nach einem erfolgten Wohnungseinbruchdiebstahl in kurzer Zeit und in unmittelbarer Nähe zu Nachfolgedelikten kommen wird? Dieser Frage geht der vorliegende Artikel anhand von Daten aus Baden-Württemberg nach. Dabei zieht er einen Vergleich mit der kommerziellen Software PRECOBS, zu deren Einsatz eine Studie in Baden-Württemberg durchgeführt wurde. Bisherige Lösungen beschränken sich auf den urbanen Raum. Deshalb wird zusätzlich untersucht, ob auch Prognosen für den ländlichen Raum möglich sind.

↳ **Keywords:** near-repeat offence – theft by burglary of a dwelling – data science – machine learning – time period of offence – criminal-geographical area

## ABSTRACT

*Is it possible to train models by means of machine learning algorithms, which may then be used to predict whether near-repeat offences will be committed shortly after a theft by burglary of a dwelling, and in the immediate vicinity of the burgled dwelling? The article explores this question, based on data from Baden-Württemberg. In this context, a comparison can be made with the PRECOBS commercial software, because a study has been conducted on the use of PRECOBS in Baden-Württemberg. The solutions found so far are restricted to urban areas. For that reason, the article additionally examines whether predictions can also be made for rural areas.*



**Daniel Haake**

arbeitete zunächst im gehobenen Polizeidienst, wobei er sowohl in der Hundertschaft, dem Streifen dienst als auch im Polizeipräsidium tätig war. Er studierte zusätzlich Informatik (B. Sc.) und anschließend Data Science (M. Sc.). Zurzeit ist er als Senior Data Scientist bei Evonik tätig.

Für seine an der Hochschule Albstadt-Sigmaringen bei Prof. Dr. Andreas Knoblauch verfasste Masterarbeit zum Thema „Prognose von Wohnungseinbrüchen mit Hilfe von Machine-Learning-Algorithmen“ wurde er mit dem Gerhard-Fürst-Preis 2020 des Statistischen Bundesamtes ausgezeichnet. Mit dem folgenden Beitrag stellt er diese Masterarbeit vor.

## 1

---

### Einleitung

---

In der polizeilichen Arbeit ist Predictive Analytics, dort als Predictive Policing bezeichnet, ein junges Gebiet. Der damalige Chef der Polizei von Los Angeles, William J. Bratton, stellte im Jahr 2008 der Öffentlichkeit Ergebnisse zur Vorhersage von Bandenkriminalität vor (Perry und andere, 2013, hier: Seite 4). Diese besagten, dass es besonders häufig zu Gewalttaten zwischen Banden kam, wenn eine Feierlichkeit einer Bande nicht polizeilich abgesichert wurde. Aus dieser Erkenntnis heraus wurden solche Feierlichkeiten anschließend immer polizeilich begleitet. William J. Bratton bezeichnete das Vorgehen als einfache Form der vorausschauenden Polizeiarbeit und prägte damit den Begriff des Predictive Policing (Bratton, 2009, hier: Seite 1 f.).

Im Jahr 2011 begann die Firma PredPol mit der gleichnamigen Software mittels mathematischer Konzepte aus der seismologischen Forschung „Epizentren“ von Eigentums- und Gewaltdelikten zu berechnen (Twachtman, 2013). In Deutschland vertreibt das Institut für musterbasierte Prognosetechnik (IfmPt) das Expertensystem PRECOBS zur Prognose von Wohnungseinbrüchen. Aus Daten der Vergangenheit zu Wohnungseinbrüchen detektiert PRECOBS Gebiete, die besonders anfällig dafür sind. Kommt es in einem solchen Gebiet zu einem Wohnungseinbruch und weist dieser zuvor definierte Merkmale auf, die für eine Serientat sprechen (sogenannte Trigger), wird ein Alarm ausgegeben, dass mit einer Nachfolgetat zu rechnen ist (Egger, 2015, hier: Seite 3).

Auch deutsche Polizeibehörden versuchen, Predictive-Policing-Lösungen zu entwickeln, beispielsweise Berlin mit KrimPro (Fiebig, 2017), Nordrhein-Westfalen mit SKALA und Hessen mit KLB-operativ (Krempel, 2018). Ähnlich der Trigger-Lösung bei PRECOBS wird anhand von sogenannten Scoring-Punkten zu Merkmalen einer Tat bei Erreichen eines Schwellwerts eine Tat als Serientat kenntlich gemacht (Heitmüller, 2017).

Bei der vorliegenden Arbeit soll prognostiziert werden, ob nach einem erfolgten Wohnungseinbruch mit einer Nachfolgetat zu rechnen ist. Zunächst werden kriminologische Theorien betrachtet, die bei der Prognose hilfreich sein können. Da die Merkmale einer Nachfolgetat

nicht vorgegeben sind, sondern aus den Mustern in den Daten erlernt werden sollen, kommt keine Trigger-Lösung zum Einsatz. Die Untersuchung beschränkt sich nicht nur auf Gebiete, die in der Vergangenheit besonders anfällig für Wohnungseinbrüche waren, sondern versucht, Muster in allen vorliegenden Daten zu finden. Weiterhin wird untersucht, ob mit dieser Herangehensweise auch Prognosen für den ländlichen Raum möglich sind. Bisher beschränken sich Prognosen auf den urbanen Raum, so auch PRECOBS (Gerstner, 2017, hier: Seite 25).

## 2

---

### Kriminologische Theorien und Studien

---

Für die Prognose von Wohnungseinbrüchen ist es wichtig zu wissen, welche Faktoren eine Rolle spielen können, dass es zu Wohnungseinbrüchen kommt. Welche Informationen sollte die Datengrundlage zum Training der Machine-Learning-Modelle aufweisen, um Prognosen zu ermöglichen?

#### 2.1 Hot-Spot-Theorie

---

Laut Definition des U.S. Department of Justice gibt es Gebiete, in denen sich Kriminalität im Allgemeinen häuft:

*«A hot spot is an area that has a greater than average number of criminal or disorder events, or an area where people have a higher than average risk of victimization.»* (Eck und andere, 2005, hier: Seite 2)

Sherman und andere stellten 1989 fest, dass innerhalb eines Jahres 50% der Notrufe, die bei der Polizei von Minneapolis eingingen, sich auf lediglich 3% der Adressen konzentrierten (Sherman und andere, 1989). Im Jahr 1995 verglich Sherman die Kriminalkarrieren von Täterinnen und Tätern mit der Frequenz, in der Straftaten an einem Ort stattfanden. Er kam zum Ergebnis, dass künftige Straftaten sechsmal besser in Bezug auf den Ort als auf den Täter vorhersagbar seien (Sherman, 1995).

In Bezug auf Wohnungseinbrüche kam eine Studie zum Ergebnis, dass vor allem der Norden der untersuchten Stadt Cambridge eine hohe Anzahl von Wohnungseinbrüchen

aufwies und 53 % der Wohnungseinbrüche in einem Drittel der Bezirke stattfanden (Bennett, 1995).

## 2.2 Repeat Victimization

Der Repeat Victimization nach weisen Personen ein erhöhtes Risiko auf, nach einer erlittenen Straftat erneut Opfer einer Straftat zu werden (Farrell/Pease, 1993, hier: Seite 5 ff.). Statistisch belegt wurde das Phänomen 1984 von Michael R. Gottfredson.

Er stellte fest, dass 31,9 % der befragten Personen mindestens einmal und 14,1 % mindestens zweimal Opfer einer Straftat wurden. [↘ Tabelle 1](#)

**Tabelle 1**

Geschätzter Grad der Viktimisierung

	Alle Straftaten	Wohnungseinbruchs- diebstahl, Vandalis- mus, Kfz-Kriminalität
	%	
Keine Viktimisierung	68,1	72,3
1 Viktimisierung	17,8	16,9
2 Viktimisierungen	6,2	5,0
3 Viktimisierungen	3,1	2,6
4 Viktimisierungen	1,8	1,3
5 Viktimisierungen	0,7	0,4
6 und mehr Viktimisierungen	2,2	1,5

Quelle: Gottfredson, 1984, Seite 41 (angepasst)

Daraus folgt, dass 44,2 % derjenigen, die Opfer einer Straftat wurden, auch noch mindestens ein zweites Mal Opfer wurden. [↘ Tabelle 2](#)

**Tabelle 2**

Reviktimisierung

	Alle Straftaten	Wohnungseinbruchs- diebstahl, Vandalis- mus, Kfz-Kriminalität
	%	
1 Viktimisierung	55,8	61,0
Mehr als 1 Viktimisierung	44,2	39,0

Bei weiteren Untersuchungen konnte festgestellt werden, dass lediglich 4 % der Opfer von Straftaten auf 44 % der stattgefundenen Straftaten entfielen (Pease/Laycock, 1996).

## 2.3 Near Repeat Victimization

Bei der Near Repeat Victimization wird untersucht, ob nach einer erfolgten Straftat der Raum selbst einem erhöhten Risiko ausgesetzt ist, dass es innerhalb eines gewissen Umkreises und innerhalb einer gewissen Zeit zu weiteren Straftaten kommt.

Empirisch untersucht wurde die Near-Repeat-Hypothese im Jahr 2003 anhand von Wohnungseinbrüchen in Brisbane, Australien (Townsend und andere, 2003, hier: Seite 615). Dabei konnte nachgewiesen werden, dass nach einem erfolgten Wohnungseinbruch innerhalb von 200 Metern und zwei Monaten eine erhöhte Wahrscheinlichkeit für weitere Wohnungseinbrüche bestand (Townsend und andere, 2003, hier: Seite 624 ff.). Anhand von Daten zu Australien, den Niederlanden, Neuseeland, dem Vereinigten Königreich und den Vereinigten Staaten wurde für mindestens 14 Tage und in einem Umkreis von 200 Metern ein erhöhtes Risiko für weitere Wohnungseinbrüche nachgewiesen (Johnson und andere, 2007, hier: Seite 206 ff.). Für Deutschland konnte bei einer Studie im Landkreis Harburg in Niedersachsen ein erhöhtes Risiko für einen Umkreis von 200 Metern und eine Dauer von sieben Tagen nachgewiesen werden (Gluba und andere, 2015, hier: Seite 371 ff.).

## 2.4 Boost-Hypothese

Ein Erklärungsansatz für (Near) Repeat Victimization ist die Boost-Hypothese, wonach Täter sehr oft in Häuser einbrechen, in die sie bereits zuvor eingebrochen sind. Dieses Vorgehen wird als „Boost“ bezeichnet und mit positiven Erfahrungen bei der ersten Tat erklärt (Clarke und andere, 2001, hier: Seite 120).

Bei einer Studie gaben Täter folgende Gründe für einen wiederholten Einbruch in dasselbe Haus an: Einfachheit und Erfolg der Tatausführung, Profitabilität, Ersetzung des Diebesguts in der angegriffenen Wohnung und nicht mitgenommene Gegenstände, für die es in der Zwischenzeit Käufer gab. Einige Täter führten an, dass Einbruch und anschließende Flucht schneller auszuführen seien, wenn man den Ort bereits kennt (Ashton und andere, 1998, hier: Seite 275 f.). Die Täter konnten durch einen Wohnungseinbruch bereits die Umgebung mit ihren Fluchtmöglichkeiten, örtlichen Besonderheiten, Einsehbarkeit der Tatobjekte und anderen

Überwachungsmöglichkeiten auskundschaften, was die Ausführung eines weiteren Wohnungseinbruchs in der Umgebung vereinfacht (Gluba und andere, 2015, hier: Seite 369). Das lässt vermuten, dass der kriminalgeografische Raum für das Vorliegen von Near Repeats einen entscheidenden Faktor darstellt.

Bestätigt wurde die Boost-Hypothese bei einer Untersuchung, wie oft es sich um dieselben Täter handelte, wenn es zur (Near) Repeat Victimization kam (Bernasco, 2008, hier: Seite 411).

Dabei konnte festgestellt werden: Je geringer die Zeitspanne und die Entfernung zwischen Erst- und Zweittat sind, desto wahrscheinlicher ist eine Tatausführung der beiden Taten durch dieselben Täter. [↪ Tabelle 3](#)

**Tabelle 3**

**Auftreten von (Near) Repeat Victimization**

Zeitliche Distanz	Räumliche Distanz						
	bis 0 m	bis 100 m	bis 200 m	bis 300 m	bis 400 m	bis 1000 m	bis 25 km
Anteil derselben Täter in %							
Bis 7 Tage	98	90	83	78	72	46	5
Bis 15 Tage	95	85	77	70	64	37	4
Bis 31 Tage	94	80	68	58	52	28	3
Bis 62 Tage	94	72	55	44	37	18	2
Bis 92 Tage	91	64	46	36	30	14	1
Bis 9 Jahre	62	13	8	5	4	2	0

Quelle: Bernasco, 2008, Seite 419 (übersetzt)

## 2.5 Flag-Hypothese

Der Flag-Hypothese nach besitzt das Objekt selbst Eigenschaften, die es für Täter für einen Einbruch als attraktiv markieren (Johnson, 2008, hier: Seite 217). Dies können Einstiegs- und Fluchtwege, aber auch das Nicht-Vorhandensein von Überwachungsmöglichkeiten sein (Gluba und andere, 2015, hier: Seite 369).

In einer Untersuchung konnte festgestellt werden, dass die Erreichbarkeit von vor allem stark befahrenen Straßen einen Einfluss darauf hat, ob ein Wohnhaus für einen Einbruch ausgewählt wird. Daraus wurde geschlossen, dass räumliche Eigenschaften in die Entscheidung von Tätern einfließen, in welches Wohnhaus sie einbrechen werden (Beavon und andere, 1994, hier: Seite 138).

## 2.6 Rational-Choice-Theorie

Der Rational-Choice-Theorie zufolge handelt es sich beim Menschen um ein rational handelndes Wesen, das Kosten und Nutzen seines Handelns abwägt (Hill, 2002, hier: Seite 50). Andere Definitionen unterteilen den Faktor Kosten feiner in Risiko und Kosten. Die Gefahr, entdeckt und damit strafrechtlich belangt zu werden, wird dabei separat als Risiko betrachtet. Als Nutzen von Wohnungseinbrecherinnen und -einbrechern kommen zum einen das gestohlene Gut, aber auch der Adrenalin-Kick oder die Anerkennung einer Gruppe von Gleichaltrigen infrage. Kosten können die Zeit, Ausgaben, um zum Tatobjekt zu gelangen, und der Aufwand für den Verkauf der gestohlenen Güter sein (Bernasco und andere, 2015, hier: Seite 121).

## 2.7 Routine-Activity-Theorie

Gemäß der Routine-Activity-Theorie müssen für das Zustandekommen von Straftaten drei Faktoren vorliegen (Cohen/Felson, 1979, hier: Seite 588):

- › mindestens ein motivierter Täter,
- › ein als geeignet angesehenes Tatobjekt,
- › das Fehlen von Schutzmechanismen.

Untersucht wurde, wie sich Veränderungen in den Lebensgewohnheiten der Bevölkerung, den Routineaktivitäten wie dem Nachgehen nach Arbeit, das Bereitstellen von Nahrung und Unterkunft, aber auch soziale Interaktion, Freizeit und Sexualität auf das Vorhandensein von Kriminalität auswirken. Die Theorie geht davon aus, dass sich nach dem Zweiten Weltkrieg die Lebensgewohnheiten geändert haben. So waren vor allem Frauen nun häufiger berufstätig, wodurch Wohnhäuser tagsüber öfter unbewacht waren und zudem die soziale Kontrolle fehlte (Cohen/Felson, 1979, hier: Seite 593 ff.).

Wenn Schutzmechanismen fehlen, sind motivierte Täter bei Vorhandensein eines geeigneten Tatobjekts eher gewillt, einen Wohnungseinbruch zu begehen. Demnach treffen Täter vor der Tatausübung eine für sie rationale Entscheidung (Gluba, 2014, hier: Seite 4).

## 3

### Datenvorverarbeitung

Das Landeskriminalamt des Landes Baden-Württemberg hat Daten von Wohnungseinbrüchen zur Verfügung gestellt, die in der Zeit vom 1. Januar 2010 bis zum 8. Januar 2018 bei der Polizei des Landes Baden-Württemberg angezeigt wurden. Es liegen Informationen vor zum Tatort, zum Tatzeitraum und ob es ein vollendeter oder versuchter Wohnungseinbruch war. Zusätzlich sind Informationen zur Törtlichkeit (zum Beispiel Einfamilienhaus, Reihenhaushaus, und so weiter), zum Zugang ins Tatobjekt, zur Begehungsweise, zum Tatmittel und zum erlangten Gut vorhanden.

### Hinzufügen zusätzlicher Informationen

Weitere Daten ergänzten die vorhandenen, zum Beispiel zeitliche Informationen. Bekannt ist lediglich der ungefähre Tatzeitraum des Wohnungseinbruchsdiebstahls, da Täter meist nicht auf frischer Tat gestellt werden und daher der genaue Tatzeitpunkt nicht bekannt ist. Vielmehr ist bekannt, wann ganz sicher der Wohnungseinbruchsdiebstahl noch nicht passiert ist und wann er anschließend festgestellt wurde. Als Tatzeitpunkt wurde der Mittelwert aus dem bekannten Tatzeitraum berechnet. Anhand dieses Tatzeitpunkts wurde zu jedem Wohnungseinbruch festgestellt, ob es sich um einen Ferien- oder Feiertag handelt und in welchem Monat, an welchem Wochentag und zu welcher Stunde des Tages der Wohnungseinbruch stattgefunden hat.

Wie aus den kriminologischen Studien hervorgeht, kann der kriminalgeografische Raum einen Einfluss darauf haben, ob es zu weiteren Wohnungseinbrüchen in einer Gegend kommt. Ergänzt wurden daher Merkmale, die Fluchtmöglichkeiten und Entdeckungsrisiko widerspiegeln könnten. Das sind beispielsweise die Entfernungen zu Autobahnanschlussstellen, Polizeistationen, Restaurants, Cafés, Biergärten, Bars, Discos, Bäckereien, Bahnhöfen, Bushaltestellen, Straßenbahnhaltestellen, Taxiständen, Kindergärten, Schulen, Hochschulen, Einkaufszentren, Supermärkten und Lebensmittelläden. Um den Urbanisierungsgrad abbilden zu können, wurde berechnet, wie viele der genannten Objekte innerhalb einer Fläche von 1 km<sup>2</sup> um den Tatort vorhanden

sind. Untersuchungen ergaben, dass auch die Anzahl von Kreuzungen einen Einfluss hat. Daher wurde auch berechnet, wie viele Kreuzungen das Straßennetz innerhalb einer Fläche von 1 km<sup>2</sup> um jeden Tatort aufweist.

Auch die Entfernung zu einer Landes- und Staatsgrenze wurde für jeden vorhandenen Wohnungseinbruch berechnet und als Merkmal für das Training der Modelle aufgenommen. Da die Zuständigkeit der Polizei den Bundesländern obliegt, könnte ein Zeitverzug in der Verständigung einer anderen Polizeibehörde die Fluchtmöglichkeiten verbessern.

Für die Berücksichtigung der Hot-Spot-Theorie wurde berechnet, wie viele Taten es zu jedem Wohnungseinbruch im Umkreis von 1 km<sup>2</sup> in den vergangenen 0 bis 3, 3 bis 7, 7 bis 28 und 28 bis 365 Tagen gegeben hat.

## 4

### Datenanalyse

#### 4.1 Nachfolgedelikte in Bezug auf Raum und Zeit

Zur Untersuchung der Near-Repeat-Theorie für Baden-Württemberg wurde berechnet, wie hoch der prozentuale Anteil an Nachfolgetaten für unterschiedlich gewählte räumliche und zeitliche Intervalle ist. [↘ Tabelle 4](#)

**Tabelle 4**  
Nachfolgedelikte in Baden-Württemberg

Zeitliche Distanz	Räumliche Distanz					
	100 m	200 m	300 m	400 m	500 m	600 m
	%					
2 Tage	7,1	9,1	10,8	12,2	13,4	14,6
3 Tage	7,5	9,8	11,9	13,6	15,2	16,7
5 Tage	8,0	11,0	13,6	15,9	18,1	20,1
7 Tage	8,5	11,9	15,1	18,0	20,6	23,1
10 Tage	9,0	13,2	17,1	20,5	23,8	26,8

Wie zu erwarten, steigt der Anteil an Nachfolgedelikten, je größer das zeitliche Intervall und der geografische Raum sind. Der Anteil an Nachfolgedelikten steigt nicht so stark an, wie durch den Anstieg des zeitlichen und räumlichen Intervalls zu erwarten wäre.

Betrachtet man das zeitliche Intervall von zwei Tagen, ist zu erkennen, dass sich der Anteil an Nachfolgedelikten nur etwas mehr als verdoppelt, obwohl der geografische Raum beim räumlichen Intervall von 600 Metern 36-mal größer ist als beim Intervall von 100 Metern (Kreisfläche  $A = \pi \cdot r^2$ ). Beurteilt man das Intervall von 100 Metern, stellt man fest, dass der Anteil an Nachfolgedelikten im Vergleich von zwei zu zehn Tagen lediglich um rund 27% steigt, obwohl das zeitliche Intervall fünfmal so groß ist.

Für ein besseres Verständnis, wie stark die Abweichung von einem zu erwartenden und dem tatsächlichen Anteil an Nachfolgedelikten gegeben ist, werden die Werte des räumlichen und zeitlichen Intervalls normalisiert. Als Normalwerte angenommen werden für das zeitliche Intervall zehn Tage und für das räumliche Intervall 600 Meter.

In Bezug auf Raum und Zeit kommt es innerhalb von 100 Metern und zwei Tagen fast 48-mal häufiger zu Nachfolgedelikten als innerhalb von 600 Metern und zehn Tagen. Je geringer der räumliche und zeitliche Abstand zu einem Wohnungseinbruch ist, desto höher ist das Risiko für eine Nachfolgetat. Dies bestätigt die Near-Repeat-Theorie für das Bundesland Baden-Württemberg. [↘ Tabelle 5](#)

**Tabelle 5**  
Normalisierte Häufigkeit von Nachfolgedelikten in Baden-Württemberg

Zeitliche Distanz	Räumliche Distanz					
	100 m	200 m	300 m	400 m	500 m	600 m
2 Tage	47,69	15,28	8,06	5,12	3,60	2,72
3 Tage	33,58	10,97	5,92	3,81	2,72	2,08
5 Tage	21,49	7,39	4,06	2,67	1,95	1,50
7 Tage	16,31	5,71	3,22	2,16	1,58	1,23
10 Tage	12,09	4,43	2,55	1,72	1,28	1,00

## 4.2 Korrelation zwischen Merkmalen und Klassenlabel

Um einen ersten Eindruck zu bekommen, welche Merkmale gut für die Prognose von Wohnungseinbrüchen geeignet sein können, wird der Korrelationskoeffizient zwischen den Merkmalen und dem Klassenlabel (boolescher Wert für das Auftreten einer Nachfolgetat innerhalb von sieben Tagen und 500 m Umkreis) berechnet. Der Höchstwert liegt bei knapp unter 0,25. Eine sehr

starke Korrelation liegt daher für keines der Merkmale vor. Die größten Korrelationswerte sind für die Anzahl an Wohnungseinbrüchen in der Vergangenheit um einen Tatort gegeben. Dabei ist der Wert umso höher, je geringer der zeitliche und der räumliche Abstand zur ursprünglichen Tat sind.

Nachfolgend korrelieren die den kriminalgeografischen Raum beschreibenden Merkmale am stärksten. Dabei steigt der Korrelationskoeffizient sowohl bei Erhöhung der Entfernung als auch des zeitlichen Abstands um die Tat. Die Merkmale, die die Anzahl von ausgewählten Orten im Umkreis angeben, weisen dabei eine positive Korrelation auf, wohingegen die Entfernung zu den ausgewählten Orten eine negative Korrelation aufweist. Je urbaner der Tatort ist, desto stärker ist die Korrelation in Bezug auf eine stattfindende Nachfolgetat.

Die Merkmale zur Begehungsweise, zum erlangten Gut, zur Tatörtlichkeit und zum Zugang zum Tatobjekt weisen keine Korrelation auf. Zeitliche Faktoren und die Entfernung zu einem Bundesland oder einer Staatsgrenze weisen ebenfalls keine Korrelation auf.

Die Korrelationskoeffizienten spiegeln lediglich die linearen Abhängigkeiten zwischen den Merkmalen und dem Klassenlabel wider. Merkmale können im Zusammenhang mit anderen Merkmalen auch das Auftreten von Nachfolgedelikten beeinflussen, auch wenn sie keine lineare Abhängigkeit mit dem Klassenlabel aufweisen. Da Merkmale, die allein keine lineare Abhängigkeit zu den Klassenlabeln aufweisen, dennoch mit anderen Merkmalen zusammen das Auftreten von Nachfolgedelikten beeinflussen könnten, wird bei der Untersuchung nicht ausschließlich auf die korrelierenden Merkmale zurückgegriffen. Die Korrelation stellt jedoch einen ersten Anhaltspunkt dar.

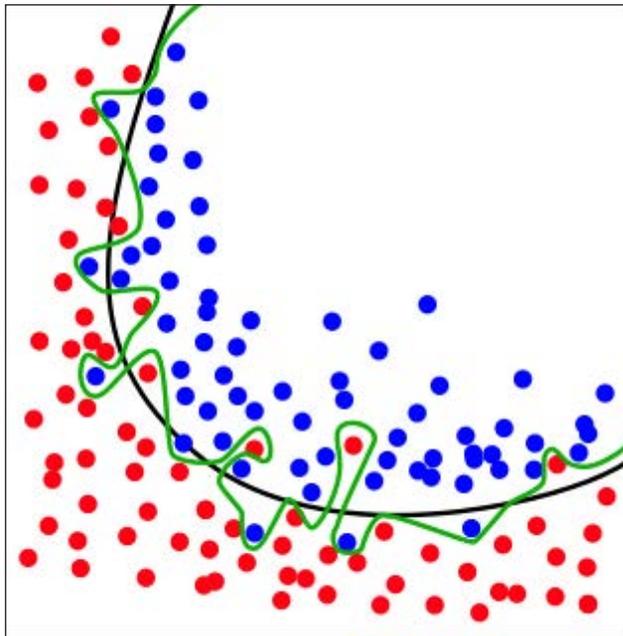
## 4.3 Training von Machine-Learning-Modellen

Mit dem überwachten Lernen (englisch: supervised learning), dem unüberwachten Lernen (englisch: unsupervised learning) und dem Verstärkungslernen (englisch: reinforcement learning) gibt es hauptsächlich drei verschiedene Formen des maschinellen Lernens (Raschka/Mirjalili, 2017, hier: Seite 2). Ziel ist, zu prognostizieren, ob nach einer erfolgten Tat mit einer weiteren Tat zu rechnen ist. Es handelt sich dabei um

eine Frage des überwachten Lernens im Sinne einer Klassifikation, da die Zielwerte zu jedem Datenvektor bekannt sind (boolescher Wert für das Auftreten einer Nachfolgetat). Es wird versucht, Muster jeder einzelnen Klasse zu identifizieren und für unbekannte Datenvektoren eine Klasse zu prognostizieren. Mathematisch ausgedrückt ist das Ziel des überwachten Lernens das Finden einer deterministischen Funktion, die als Trennebene zwischen den Klassen dient. Auf neue Datenvektoren angewendet soll die deterministische Funktion die Zugehörigkeit zu einer Klasse liefern, wobei die Funktion eine möglichst geringe Fehlerrate aufweisen soll. Bei der Arbeit wurden die Machine-Learning-Algorithmen Support Vector Machines, Neuronale Netze, Random Forest, XGBoost und ein Soft-Voting dieser Modelle verwendet.

In praktischen Anwendungsfällen sind Daten oftmals verrauscht. Die Lernalgorithmen können Muster im Rauschen erkennen, die nicht reproduzierbar sind. Das Ziel muss es sein, das Signal und nicht das Rauschen der Daten zu finden (Silver, 2013). [↪ Grafik 1](#)

**Grafik 1**  
Signal und Rauschen



Die schwarze Linie zeigt das eigentliche Signal in den Daten, die grüne Linie erkennt Muster im Rauschen selbst, was zu Overfitting führt (EliteDataScience, 2017)

2021 - 0155

Mittels Hyperparametertuning bei den Lernalgorithmen wird versucht, das Muster in den Daten zu erkennen, also ein Overfitting zu vermeiden. Einfache Modelle generalisieren im Allgemeinen besser. Zu einfache Modelle können jedoch das Muster nicht erkennen und es kommt zum Underfitting (Géron, 2017, hier: Seite 28). Für das Tuning wurde die Datenmenge in Trainings- und Validierungsmengen unterteilt und eine zusätzliche Testmenge zurückgehalten. Das Modell wird anhand der Trainingsmenge trainiert. Die Anpassung der Hyperparameter erfolgt auf Basis der Ergebnisse, die das Modell auf den Validierungsmengen erzielt. Erst zum Schluss wird ein einziges Mal das endgültige Modell auf die Testmenge angewendet. Dadurch ist eine Abschätzung möglich, wie das Modell auf unbekannte Daten funktioniert, da die Testmenge weder für das Training noch für die Validierung genutzt wurde. Das Vorgehen wird auch als holdout validation bezeichnet (Raschka/Mirjalili, 2017, hier: Seite 190). Zur Anwendung kam eine 5-fold cross validation mit einem time series split. Dadurch liegen sowohl die jeweiligen Validierungsdaten als auch der Testdatensatz in Bezug auf die Trainingsdaten immer in der Zukunft. So wäre es auch beim Einsatz eines trainierten Modells in der Realität, was ermöglicht, auf neue, unbekannte Daten abzuschätzen.

Optimiert werden die Modelle anhand des  $F_{1/2}$ -Maßes, einer Spezialform des  $F_{\beta}$ -Maßes. Dabei werden sowohl die Metriken Precision und Recall betrachtet, wobei ein größerer Fokus auf die Precision gelegt wird. Ein Recall-Wert von 1, also dass jede tatsächlich eingetretene Nachfolgetat erkannt wird, ist auch ohne Prognosesoftware möglich, indem man immer von einer Nachfolgetat ausgeht. Das ist für die polizeiliche Praxis kein gangbarer Weg, da nicht nach jeder erfolgten Tat polizeiliche Maßnahmen für den Bereich über mehrere Tage durchgeführt werden können. Nicht umsonst gilt das Sprichwort aus der Einsatzlehre: „Wer alles schützt, schützt nichts.“ (Thust, 2013) Viel wertvoller für die polizeiliche Praxis ist eine Software, die Alarme von zu erwartenden Nachfolgedelikten mit einer möglichst hohen Precision ausgibt. So ist es möglich, polizeiliche Maßnahmen gezielt dort durchzuführen, wo auch tatsächlich mit einer hohen Wahrscheinlichkeit von Delikten zu rechnen ist. Das erhöht auch die Akzeptanz bei den Beamtinnen und Beamten, die für den Erfolg einer Software mitentscheidend ist. Eine hohe Precision ist daher zielführend, weshalb für die Optimierung der Modelle der  $F_{1/2}$ -Score herangezogen wird.

PRECOBS wurde in der Zeit vom 30. Oktober 2015 bis zum 30. April 2016 von der Polizei des Landes Baden-Württemberg in den Präsidien Karlsruhe und Stuttgart getestet (Gerstner, 2017, hier: Seite 17). Zwar werden die Alarme für sieben Tage und 500 Meter ausgegeben. Dennoch wurde bei der Untersuchung gemessen, ob es innerhalb von sieben Tagen und 600 Metern zu einer Nachfolgetat gekommen ist. Aus der Untersuchung geht hervor, dass dabei eine Genauigkeit der Alarme in Bezug auf den erweiterten Raum von 600 Metern von 24,8% erzielt werden konnte (Gerstner, 2017, hier: Seite 48). Werte für den Recall wurden nicht veröffentlicht und können deshalb nicht verglichen werden. Für die Vergleichbarkeit mit PRECOBS werden die Modelle in diesem Artikel mit dem Zielvektor trainiert, der angibt, ob es nach einer Tat innerhalb von sieben Tagen und 500 Metern zu einer Nachfolgetat gekommen ist. Abschließend wird anhand des Testsets betrachtet, ob es dann innerhalb von 600 Metern zu einer Nachfolgetat gekommen ist.

Standardmäßig wird ab einem Schwellenwert von 50% Wahrscheinlichkeit, dass ein Datenvektor zu einer Klasse gehört, diese Klasse für den jeweiligen Datenvektor prognostiziert. Über die Änderung des Schwellenwerts kann der sogenannte Precision-Recall-Tradeoff gesteuert werden. Durch Erhöhung des Schwellenwerts kann der Wert für die Precision erhöht werden, bei gleichzeitigem Herabsinken des Wertes für den Recall, und umgekehrt. Ziel ist es nun, den Schwellenwert so zu wählen, dass es eine gewisse Anzahl an Alarmen gibt, die gut durch die Polizei mit Einsatzmaßnahmen begleitet werden können und zu einer möglichst hohen Precision führen. Damit sich die Polizei gezielt auf Einsätze mit einer hohen Erfolgsaussicht konzentrieren kann, wird eine höhere Precision gegenüber einer höheren Anzahl von Alarmen präferiert. Ein perfekt funktionierendes System mit einer Precision von 1 und einem Recall von 1 würde so viele Alarme ausgeben, wie es Nachfolgetaten gibt. Bei 10 000 Wohnungseinbrüchen würde ein perfekt funktionierendes System, das für zwei Tage und 100 Meter trainiert wurde, rund 710 Alarme auswerfen, ein System, das für zehn Tage und 600 Meter trainiert wurde, rund 2 680 Alarme (siehe Tabelle 4). Als geeignete Anzahl an Alarmen wird ein Wert von 500 bis 1 000 je 10 000 Wohnungseinbrüchen angenommen. Daher wird der Schwellenwert des besten Modells so eingestellt, dass einerseits ungefähr 500, andererseits ungefähr 1 000 Alarme zu erwarten sind.

## 4.4 Ergebnisse

Zunächst wurde mithilfe aller bekannten Merkmale zu den Wohnungseinbrüchen trainiert. Die Korrelationskoeffizienten zeigten lineare Abhängigkeiten nur für eine Teilmenge der Merkmale, sodass auch mit verschiedenen Subsets an Merkmalen trainiert wurde. Tatsächlich wurden die besten Ergebnisse erzielt, wenn lediglich drei Merkmale für das Training genutzt wurden: die Anzahl der den kriminalgeografischen Raum beschreibenden Merkmale, die Anzahl der Delikte in der Vergangenheit und die Anzahl der Straßenkreuzungen innerhalb einer Fläche von einem Quadratkilometer.

Dargestellt werden hier die je Algorithmus besten Ergebnisse, ausgewählt nach dem jeweils höchsten  $F_{1/2}$ -Measure anhand der Ergebnisse auf den Validierungsmengen nach erfolgtem Training mittels cross validation mit time series split. Beim Training mit dem Klassenlabel für sieben Tage und 500 Meter konnte beim Random Forest mit angepasstem Schwellenwert auf dem Validierungssatz eine Precision von knapp über 50% und beim Testset von knapp über 40% erreicht werden. [↘ Tabelle 6](#) Sowohl stabilere als auch bessere Ergebnisse konnten beim Training mittels XGBoost und dem neuronalen Netz erreicht werden. So wurden Werte für die Precision zwischen 52 und 57% erzielt.

**Tabelle 6**

**Angepasster Schwellenwert zur Ausgabe von ungefähr 500 Alarmen für sieben Tage und 500 Meter**

Algorithmus	Validierungsmenge			Testmenge		
	Alarme	Precision	Recall	Alarme	Precision	Recall
Random Forest	572	0,507	0,130	464	0,409	0,109
XGBoost	673	0,547	0,164	427	0,519	0,127
Neuronales Netz	567	0,572	0,145	514	0,516	0,152
Support Vector Machine	518	0,600	0,139	345	0,553	0,109
Soft Voting	557	0,590	0,147	346	0,542	0,107

Für eine bessere Vergleichbarkeit mit den von PRECOBS erzielten Ergebnissen wird mit den für sieben Tage und 500 Meter trainierten Modellen überprüft, ob es innerhalb von sieben Tagen und 600 Metern zu Nachfolgedelikten gekommen ist. [↘ Tabelle 7](#) zeigt, dass der Anteil an stattgefundenen Nachfolgedelikten um drei bis sechs Prozentpunkte steigt. Besonders hoch ist hierbei der Anteil beim Modell des neuronalen Netzes, wo

**Tabelle 7**

Korrekte Alarme innerhalb von sieben Tagen und 600 Metern bei auf sieben Tage und 500 Meter trainierten Modellen<sup>1</sup>

Algorithmus	Validierungsmenge		Testmenge
	%		
Random Forest	53,7		43,6
XGBoost	58,0		55,5
Neuronales Netz	59,9		57,5
Support Vector Machine	62,4		58,5
Soft Voting	61,7		57,5

<sup>1</sup> Bei einem angepassten Schwellenwert für ungefähr 500 Alarme.

Werte von 57,5 bis knapp 60% erreicht werden können. Die Precision ist daher im Vergleich zu den von PRECOBS erreichten 24,8% zwei- bis zweieinhalbmals so hoch.

Bei der Einstellung des Schwellenwerts auf ungefähr 1 000 Alarme fallen alle Modelle bei der Testmenge unter die Grenze von 1 000 Alarmen. Hierbei verlieren sowohl die Precision als auch der Recall einige Prozentpunkte. Generell können für sieben Tage und 500 Meter auf der Testmenge Werte von 41,1 bis 50% erreicht werden.

➔ [Tabelle 8](#)

**Tabelle 8**

Angepasster Schwellenwert für ungefähr 1 000 Alarme für sieben Tage und 500 Meter

Algorithmus	Validierungsmenge			Testmenge		
	Alarme	Precision	Recall	Alarme	Precision	Recall
Random Forest	1 116	0,470	0,234	921	0,411	0,216
XGBoost	1 102	0,520	0,256	711	0,500	0,181
Neuronales Netz	1 134	0,522	0,264	735	0,477	0,201
Support Vector Machine	1 132	0,533	0,269	809	0,480	0,222
Soft Voting	1 114	0,521	0,259	764	0,473	0,207

Für die Vergleichbarkeit mit PRECOBS wird auch bei ungefähr 1 000 Alarmen geprüft, wie oft es nach einem Alarm innerhalb von sieben Tagen und 600 Metern zu Nachfolgedelikten gekommen wäre. Hierbei wurde festgestellt, dass ein Anteil an korrekten Alarmen mit Werten zwischen 44,3 und 51,3% auf der Testmenge erreicht werden kann. Auch bei der Einstellung des Schwellenwerts auf 1 000 zu erwartende Alarme können so deutlich bessere Ergebnisse erzielt werden als bei PRECOBS mit 24,8%. ➔ [Tabelle 9](#)

**Tabelle 9**

Korrekte Alarme innerhalb von sieben Tagen und 600 Metern bei auf sieben Tage und 500 Meter trainierten Modellen<sup>1</sup>

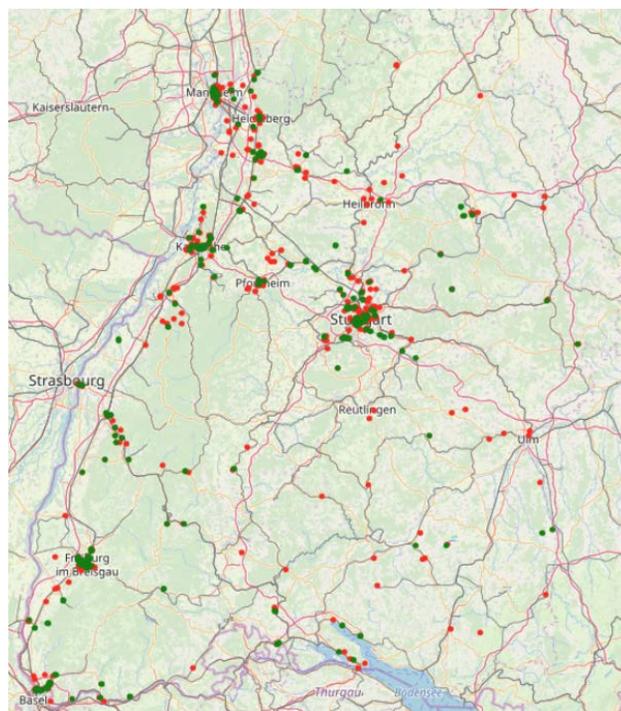
Algorithmus	Validierungsmenge		Testmenge
	%		
Random Forest	49,9		44,3
XGBoost	54,8		50,0
Neuronales Netz	55,1		51,3
Support Vector Machine	53,3		51,3
Soft Voting	55,0		50,4

<sup>1</sup> Angepasster Schwellenwert für ungefähr 1 000 Alarme.

(Korrekte) Alarme wurden dabei nicht nur in Großstädten ausgegeben, sondern auch in Neustadt, Triberg, Erolzheim, Rinnen, Walldürn und Scherzheim. ➔ [Grafik 2](#) Es kann daher festgehalten werden, dass (korrekte) Prognosen sowohl für Großstädte als auch den ländlicheren Raum möglich sind.

**Grafik 2**

Alarme des neuronalen Netzes für sieben Tage und 500 Meter bei Einstellung des Schwellenwerts auf ungefähr 1 000 Alarme



● korrekte Alarme ● falsche Alarme

2021 - 0156

## 5

---

### Fazit

---

Prognosen mithilfe von Machine-Learning-Algorithmen, die vor einem zu erwartenden Wohnungseinbruchsdiebstahl innerhalb von sieben Tagen und 500 Metern um das ursprüngliche Delikt warnen, können mit einer Genauigkeit von etwa 52 bis 55 % erzeugt werden („Precision“), innerhalb von 600 Metern mit einer Genauigkeit von rund 55 bis 58 %. Bei einer Studie zum Einsatz von PRECOBS in Baden-Württemberg konnten Werte von knapp 25 % für die Precision nachgewiesen werden. Die im vorliegenden Artikel beschriebenen Werte liegen demnach weit darüber und können teilweise mehr als verdoppelt werden.

Prognosen von Wohnungseinbrüchen waren, im Gegensatz zu PRECOBS und anderen bisher eingesetzten Lösungen, nicht nur für den urbanen, sondern auch für den ländlichen Raum möglich. Da täterspezifische Merkmale zur Prognose von Wohnungseinbrüchen nicht betrachtet werden müssen, können Prognosen unmittelbar nach Bekanntwerden eines Wohnungseinbruchsdiebstahls ohne Zeitverzug bei der Polizei erzeugt werden. Je weiter eine Tat zurückliegt, desto geringer wird das Risiko von Nachfolgedelikten, weshalb polizeiliche Maßnahmen umgehend durchgeführt werden sollten. [📄](#)

## LITERATURVERZEICHNIS

---

- Ashton, Julie/Brown, Imogen/Senior, Barbara/Pease, Ken. *Repeat victimisation: offenders accounts*. In: International Journal of Risk, Security and Crime Prevention. Jahrgang 3. Heft 4/1998, Seite 269 ff.
- Beavon, Daniel J. K./Brantingham, Patricia L./Brantingham, Paul J. *The influence of street networks on the patterning of property offenses*. Crime Prevention Studies. Jahrgang 2. 1994, Seite 115 ff.
- Bennett, Trevor. *Identifying, explaining, and targeting burglary 'hot spots'*. In: European Journal on Criminal Policy and Research. Jahrgang 3. Ausgabe 3/1995, Seite 113 ff.
- Bernasco, Wim. *Them again?: Same-offender involvement in repeat and near repeat burglaries*. In: European Journal of Criminology. Jahrgang 5. Ausgabe 4/2008, Seite 411 ff.
- Bernasco, Wim/Johnson, Shane D./Ruiter, Stijn. *Learning where to offend: Effects of past on future burglary locations*. In: Applied Geography. Jahrgang 60. 2015, Seite 120 ff.
- Clarke, Ronald V./Perkins, Elizabeth/Smith Jr., Donald J. *Explaining repeat residential burglaries: An analysis of property stolen*. In: Crime Prevention Studies. Jahrgang 12. 2001, Seite 119 ff.
- Cohen, Lawrence E./Felson, Marcus. *Social Change and Crime Rate Trends: A Routine Activity Approach*. In: American Sociological Review. Jahrgang 44. Ausgabe 4/1979, Seite 588 ff.
- Eck, John E./Chainey, Spencer/Cameron James G./Leitner, Michael/Wilson, Ronald E. *Mapping Crime: Understanding Hot Spots*. U.S. Department of Justice. Washington, D. C. 2005.
- Egger, Bernhard. *Positionspapier zum Einsatz von PRECOBS bei der Bayerischen Polizei*. In: Forum Predictive Policing und geografische Kriminalitätsanalyse. Bundeskriminalamt, Landeskriminalamt Bayern. 2015.
- EliteDataScience. *Overfitting in Machine Learning: What it is and how to prevent it*. 2017. [Zugriff am 4. März 2021]. Verfügbar unter: <https://elitedatascience.com/overfitting-in-machine-learning>
- Farrell, Graham/Pease, Ken. *Once bitten, twice bitten: Repeat victimisation and its implications for crime prevention*. Police Research Group. London 1993.
- Fiebig, Peggy. *Der „Minority Report“ wird Wirklichkeit*. In: Legal Tribune Online. 2017. [Zugriff am 4. März 2021]. Verfügbar unter: [www.lto.de](http://www.lto.de)
- Géron, Aurélien. *Hands-On Machine Learning with Scikit-Learn & TensorFlow*. O'Reilly Media. Sebastopol 2017.

## LITERATURVERZEICHNIS

---

Gerstner, Dominik. *Predictive Policing als Instrument zur Prävention von Wohnungseinbruchdiebstahl – Evaluationsergebnisse zum Baden-Württembergischen Pilotprojekt P4*. Max-Planck-Institut für ausländisches und internationales Strafrecht. Freiburg im Breisgau 2017.

Gluba, Alexander. *Predictive Policing – eine Bestandsaufnahme*. Landeskriminalamt Niedersachsen. Hannover 2014.

Gluba, Alexander/Heitmann, Stefan/Hermes, Nina. *Reviktimisierungen bei Wohnungseinbrüchen: Eine empirische Untersuchung zur Bedeutung des Phänomens der (Near) Repeat Victimization im Landkreis Harburg*. In: *Kriminalistik*. Ausgabe 6/2015, Seite 368 ff.

Gottfredson, Michael R. *Victims of crime: The dimension of risk*. In: Great Britain Home Office Research Study. Number 81. 1984.

Heitmüller, Ulrike. *Predictive Policing: Die deutsche Polizei zwischen Cyber-CSI und Minority Report*. heise online. 2017. [Zugriff am 4. März 2021]. Verfügbar unter: [www.heise.de](http://www.heise.de)

Hill, Paul B. *Rational-Choice-Theorie*. Transcript. 2002.

Johnson, Shane D. *Repeat burglary victimisation: A tale of two theories*. In: *Journal of Experimental Criminology*. Jahrgang 4. Ausgabe 3/2008, Seite 215 ff.

Johnson, Shane D./Bernasco, Wim/Bowers, Kate J./Elffers, Henk/Ratcliffe, Jerry/Rengert, George/Townsley, Michael. *Space-time patterns of risk: A cross national assessment of residential burglary victimization*. In: *Journal of Quantitative Criminology*. Jahrgang 23. 2007, Seite 201 ff.

Krempf, Stefan. *Predictive Policing: Die Polizei arbeitet verstärkt wie ein Geheimdienst*. heise online. 2018. [Zugriff am 4. März 2021]. Verfügbar unter: [www.heise.de](http://www.heise.de)

Pease, Ken/Laycock, Gloria. *Revictimization: Reducing the Heat on Hot Victims*. National Institute of Justice. Washington, D. C. 1996.

Perry Walter L./McInnis, Brian/Price, Carter C./Smith, Susan C./Hollywood, John S. *Predictive Policing – The Role of Crime Forecasting in Law Enforcement Operations*. RAND Corporation. 2013.

Raschka, Sebastian/Mirjalili, Vahid. *Python Machine Learning – Second Edition*. Packt. Birmingham 2017.

Sherman, Lawrence W./Gartin, P. R./Buerger, M. E. *Hot spots of predatory crime: Routine activities and the criminology of place*. In: *Criminology*. Jahrgang 27. 1989, Seite 27 ff.

Sherman, Lawrence W. *Hot spots of crime and criminal careers of places*. In: *Crime Prevention Studies*. Ausgabe 4/1995, Seite 35 ff.

### LITERATURVERZEICHNIS

---

Silver, Nate. *The signal and the noise*. Penguin Books Ltd. 2013.

Thust, Rüdiger. *Editorial*. In: *der kriminalist*. Ausgabe 5/2013. [Zugriff am 15. März 2021]. Verfügbar unter: [www.bdk.de](http://www.bdk.de)

Townsley, Michael/Homel, Ross/Chaseling, Janet. *Infectious burglaries: A test of the near repeat hypothesis*. In: *The British Journal of Criminology*. Jahrgang 43. Ausgabe 3/2003, Seite 615 ff.

Twachtman, John. *Government Technology Magazine Features PredPol Deployment in Tacoma*. *PredPol*, 25. September 2013. [Zugriff am 5. März 2021]. Verfügbar unter: [www.predpol.com](http://www.predpol.com)

U. S. Department of Justice, Bureau of Justice Assistance. *Transcript: Perspectives in law enforcement – the concept of predictive policing: An interview with Chief William Bratton*. Washington, D. C. 2011.

**Herausgeber**  
Statistisches Bundesamt (Destatis), Wiesbaden

---

**Schriftleitung**  
Dr. Daniel Vorgrimler  
Redaktionsleitung: N. N.  
Redaktion: Ellen Römer

---

**Ihr Kontakt zu uns**  
[www.destatis.de/kontakt](http://www.destatis.de/kontakt)

---

**Erscheinungsfolge**  
zweimonatlich, erschienen im April 2021  
Ältere Ausgaben finden Sie unter [www.destatis.de](http://www.destatis.de) sowie in der [Statistischen Bibliothek](#).

---

Artikelnummer: 1010200-21002-4, ISSN 1619-2907

---

**Fotorechte:**  
© iStock.com/malerapaso/12249182 (Seite 88)  
© iStock.com/kynny/497829044 (Seite 88)

---

© Statistisches Bundesamt (Destatis), 2021  
Vervielfältigung und Verbreitung, auch auszugsweise, mit Quellenangabe gestattet.