

# Predictive Policing

Simon Egbert und Maximilian Heimstädt

*Beitrag zur Ad-Hoc-Gruppe »Zukunft der Prädiktion. Gesellschaftliche Folgen algorithmischer Vorhersage«*

## Einführung

Im Rahmen des Forschungsprojektes „The Future of Prediction“, welches von Elena Esposito (Esposito 2023) vorgestellt wird, befasst sich unser Teilprojekt mit den gesellschaftlichen Folgen von algorithmischer Vorhersage in der Polizeiarbeit. Wenn es um algorithmische Vorhersagen geht, ist *Predictive Policing* oftmals einer der ersten Begriffe der fällt. Es gibt Kinofilme, wie *Minority Report*, in denen Predictive Policing zum Thema gemacht wird. Es gibt Werbeclips in denen Softwarefirmen, wie z. B. IBM, ihre Predictive-Policing-Software darstellen. Und es gibt eine mittlerweile kaum mehr überschaubare Fülle an wissenschaftlicher Literatur (Ferguson 2017; O’Neil 2016; Bennett Moses und Chan 2018; Kaufmann et al. 2019; Ratcliffe et al. 2020; Sandhu und Fussey 2021; Strikwerda 2021; Hardyns und Rummens 2018; Wilson 2017; Egbert und Krasmann 2020), die Aussagen über die gesellschaftlichen Konsequenzen von Predictive Policing tätigt.

Was es jedoch bisher kaum gibt, sind ethnografische Studien, die tiefe Einblicke ermöglichen darin was Polizist:innen genau machen, wenn sie Predictive Policing umsetzen. Eine Ausnahme hierbei stellt die Arbeit von Sarah Brayne (2017, 2021) dar. Brayne war über mehrere Monate hinweg mit der Polizei in Los Angeles unterwegs und hat früher als die meisten anderen Wissenschaftler:innen Einblicke in die Veränderungen des Polizeialltags durch digitale, u. a. prädiktive, Technologien geliefert. Bei genauerer Betrachtung liefert Brayne jedoch eher breite als tiefe Einblicke. Sie entwirft ein sehr allgemeines Bild, auf welche verschiedenen Arten sich Polizeiarbeit durch neue Technologien, Daten, und Infrastrukturen verändert, insbesondere mit Blick auf polizeiliche Überwachungspraktiken. Aussagen über die gesellschaftlichen Konsequenzen von algorithmischer Vorhersage kann sie damit unserer Ansicht nach nur sehr begrenzt tätigen.

Eine weitere Studie zur Umsetzung von Predictive Policing, die auf ethnografischen Daten basiert, liefern Waardenburg et al. (2022), die über zwei Jahre Analyst:innen der niederländischen Polizei begleitet haben und analysieren, wie diese die Prognosen für die Anwender:innen auf der Straße übersetzen müssen,

Ferner ist, wenn es um ethnografische Studien über Predictive Policing geht, für den deutschsprachigen Raum noch die Studie von Simon Egbert und Matthias Leese zu nennen (Egbert und Leese 2021), in dessen Kontext bereits die Übersetzung von algorithmischer Prognose in konkrete Polizeiarbeit, vor allem mit Bezug auf die technisch eher wenig avancierte Software PRECOBS, thematisiert wird. Zwar haben die Autoren auch zumindest kurze ethnografische Feldaufenthalte durchgeführt, in denen sie die Prognoseerstellung beobachtet haben, der empirische Fokus lag aber auf der Dokumenten- und

Interviewebene. Auch findet eine ethnografische Begleitung der Streifenkräfte, die die Prognosen auf der Straße umsetzen, nicht statt.

Hier setzen wir mit unserem Teilprojekt an. Wir streben eine ethnografische Studie der gesamten soziotechnischen Kette des „doing predictive policing“ an – also eine detailreiche, empirische Analyse über die konkrete Art und Weise, wie in der Polizei mit Hilfe von Machine-Learning-Algorithmen Prognosen erstellt und umgesetzt werden (vgl. a. Egbert und Heimstädt 2023).

Im Folgenden werden wir das von uns anvisierte Forschungsdesign vorstellen und begründen sowie die von Esposito (2023) vorgestellten Thesen zur algorithmischen Vorhersage – Undurchsichtigkeit, Performativität, Individualisierung – auf unseren Fall von Predictive Policing beziehen und diskutieren.

## Ethnografisches Forschungsdesign

Seit 2014 wird in Deutschland prognosebasierte Polizeiarbeit betrieben. In bislang sieben Bundesländern wurde Predictive Policing mindestens pilotiert, davon in fünf im polizeilichen Regelbetrieb eingesetzt (Egbert und Kornehl 2022). Derzeit (Stand: Dezember 2022) wird unserem Kenntnisstand nach noch in Berlin (KrimPro), Hessen (hessenDATA) und Nordrhein-Westfalen (SAKALA | Prognosen) Prognosesoftware eingesetzt. Die Bundesländer unterscheiden sich darin, für welche Delikttypen Prognosen erstellt werden, fast immer werden jedoch auch Prognosen für Wohnungseinbruchdiebstahl erstellt (ebd.). Andere Delikttypen, für die Prognosen erstellt werden, sind beispielsweise Gewerbeeinbrüche oder Autoeinbrüche bzw. -diebstähle. Wir werden uns im Verlauf unserer Studie vor allem Prognosen in Bezug auf Wohnungseinbruchdiebstähle ansehen, da wir hier erwarten, dass Veränderungen der Polizeiarbeit durch algorithmische Prognosen am deutlichsten sichtbar sind, einfach weil diese Art von Prognosen am längsten erstellt und auch am häufigsten angewendet werden.

Darüber hinaus war uns bei der Fallauswahl wichtig, dass es sich um eine Prognosesoftware handelt, die von der betreffenden Polizei selbst entwickelt wurde. Denn grundsätzlich stehen die an Predictive Policing interessierten Behörden vor der Frage, ob sie Prognosesoftware eines Drittanbieters einkaufen oder ob sie diese selbst entwickeln wollen (ebd.). Wir werden die Software in einem Bundesland untersuchen, wo die Software selbst programmiert und entwickelt wurde, da wir uns dadurch erhoffen, dass wir tiefere Einblicke in die Erstellung der Prognosen bekommen. Hier geht es also nicht um die Transparenz oder Intransparenz der Prognosen aufgrund von Machine Learning (dazu später mehr), sondern um Undurchsichtigkeiten aus Gründen von Geschäftsgeheimnissen (z.B. Ferguson 2017, S. 136). Eben-diese Intransparenzen wollen wir so weit wie möglich ausklammern.

Wir haben bereits ein Bundesland gefunden, in dem Predictive Policing für Wohnungseinbruchdiebstahl (WEB) durchgeführt wird und in dem das Landeskriminalamt die Prognosesoftware selbst entwickelt hat. Die betreffende Polizei besteht, wie alle Polizeien in Deutschland, aus einem komplexen Geflecht an Organisationen. Für uns interessant sind hierbei insbesondere das Landeskriminalamt (LKA), die übergeordneten lokalen Polizeibehörden, in der Regel auf Kreisebene sowie die lokalen Polizeistationen, wo die polizeilichen Endanwender:innen der Prognosen, also die Streifenkräfte, beheimatet sind. Eine Aufgabe des LKAs ist es, praxisnahe Forschung zu Polizeithemen durchzuführen und darauf aufbauend nützliche (digitale) Tools für die Polizei zu entwickeln. Dafür gibt es im betreffenden Landeskriminalamt eine Forschungsstelle, in der die wöchentlichen Vorhersagen über diejenigen Gebiete erstellt werden, in denen ein Wohnungseinbruch wahrscheinlich ist. Diese Prognosen werden dann ebenfalls wöchentlich an die übergeordneten lokalen Polizeibehörden geschickt, wo Analyst:innen die Prognosen bewerten und ggf. an die betroffenen Polizeistationen weiterleiten.

Um die Vorhersagen vom „Labor“ bis auf die „Straße“ zu verfolgen, werden wir folgendes Forschungsdesign verfolgen: Wir verbringen über den Zeitraum von mehreren Monaten mehrere Tage lang Zeit mit dem Team der Forschungsstelle im Landeskriminalamt – dem „Labor“. Zusätzlich haben wir Zugang zu drei lokalen Polizeibehörden mit unterschiedlich hohem Aufkommen an Vorhersagen – die „Straße“. Auch hier können wir über einen längeren Zeitraum immer wieder vereinzelt Tage zwecks Beobachtung verbringen. Da wir zwei Forschende sind, können wir uns aufteilen, so dass der eine bei der Erstellung der Prognosen im LKA dabei ist und der andere in der Kreispolizeibehörde wartet und die Verfolgung einer konkreten Prognose aufnimmt („team based ethnography“, siehe Egbert und Heimstädt 2023).

## Die Reise der Prognose: Das „Labor“

Unser Ziel ist es also, die Wohnungseinbruchsprognosen vom LKA bis auf die Straßen der betroffenen Gebiete zu verfolgen. Bisher waren wir nur im LKA und können an dieser Stelle mithin nur von diesem Teil der prognostischen Reise berichten.

In der Forschungsstelle des LKA ist immer montags Prognosetag. Auch wenn die ganze Woche über an den Prognosealgorithmen gearbeitet wird, werden immer nur am ersten Tag der Woche die Prognosen für die laufende Woche erstellt und an die lokalen Polizeidienststellen verschickt. Ziel ist es, dass die Prognosen bis zum Mittag versendet werden. Damit das gelingt, gibt es Absprachen im Team, dass jeden Montag eine Person früh, möglichst vor 8 Uhr, ins Büro kommt und die Prognoseerstellung anstößt. Hierfür nutzt die Person einen Computer, der ans Netz der Polizei angeschlossen ist und lädt aus mehreren Datenbanken die relevanten Kriminalitätsdaten der letzten Woche runter (insb. über die in der vergangenen Woche verübten Einbrüche). Diese Daten werden auf einem USB-Stick gespeichert. Der USB-Stick mit den Daten wird dann in einen anderen Raum getragen, in dem die Data Scientists der Forschungsstelle sitzen. Auf ihren Computern, die ans Internet angeschlossen sind, aber aus Sicherheitsgründen wiederum nicht ans polizeiliche Netz, ist die für die Prognoseerstellung notwendige Software installiert, das Statistikprogramm R, um aus den neu gezogenen Daten – in Kombination mit dem alten Datenbestand – die Prognosen für Wohnungseinbruchdiebstähle zu errechnen. Auf diesen Computern liegt auch das Prognose-Modell, eine Sammlung an Skripten, die über R ausgeführt werden. Der/die diensthabende Data Scientist stößt die Erstellung der Prognosen an und je nach Umfang der neuen Daten dauert diese Berechnung wenige Minuten bis über eine Stunde. Hierbei kommt es immer wieder zu Fehlermeldungen, die von den Data Scientists behoben werden müssen. Oft handelt es hierbei um Probleme mit der Datenzuordnung bzw. der Variablenbenennung.

Das Ergebnis dieser Berechnungen sind Excel-Tabellen. Für jede lokale Polizeibehörde entsteht stets eine Tabelle, in der für jedes Wohngebiet – in der Regel mehrere Dutzend pro Behörde – ein Prognose-score zwischen 0 und 100 angegeben ist. Dieser Wert ist der Kern der Prognose. In dieser Excel-Tabelle sind alle Wohngebiete angegeben und nach Prognosewert absteigend geordnet. Im Ordner mit den Ergebnissen der Prognoseberechnung findet sich indes oft noch ein zweiter Tabellentyp. Für manche der lokalen Polizeibehörden wird eine weitere Excel-Tabelle mit denjenigen Prognosen erstellt, die gemäß Berechnung einen hohen Score für einen Wohnungseinbruchdiebstahl in dem betreffenden Gebiet ausweisen. Diese Tabelle enthält somit eine Auswahl der am stärksten gefährdeten Wohnquartiere im Einzugsgebiet der entsprechenden Behörde. Wenn der Einzugsbereich einer lokalen Polizeibehörde zum Beispiel in 40 Wohnquartiere aufgeteilt ist, ist es möglich, dass eine zweite Tabelle erstellt wird, die die fünf Quartiere mit dem höchsten prädiktiven Score enthält. Es kann aber auch sein, dass die Predictive Policing Software keine zweite Tabelle für eine lokale Polizeibehörde in einer bestimmten Woche

ausgibt, da kein wohnquartiersbezogener Score hinreichend groß war. Am Ende der Berechnung erschafft die Software somit eine Situation, in der für einige Kreispolizeibehörden „gute“ Prognosen vorliegen und für andere eben nicht. In den lokalen Behörden wird wiederum unterschiedlich gehandhabt, welche Prognosen für sie im operativen Alltag relevant sind. Während einige beispielsweise nur die „qualitätsgeprüften“ Prognosen nutzen, schauen anderen sich nur die große Tabelle mit allen Wohngebieten an und wählen daraus die für sie am geeignetsten erscheinenden aus.

Im letzten Schritt im Prozess der Prognoseerstellung werden die Excel-Tabellen wieder per USB-Stick in das ursprüngliche Büro getragen und dort auf den Server in das Polizeinetz hochgeladen. Anschließend wird eine vorformulierte E-Mail an die Ansprechpartner:innen der lokalen Dienststellen versendet, worin mitgeteilt wird, dass die Prognosen der neuen Woche nun auf dem Server abrufbar sind. Was ab diesem Zeitpunkt mit den Prognosen auf der lokalen Ebene geschieht, darüber können die Mitglieder der Forschungsabteilung nur spekulieren. Man hat sich nämlich von Beginn der Implementierung der Prognosesoftware an dafür entschieden, die Umsetzung der Prognose nicht nachzuverfolgen, um die Akzeptanz der lokalen Kräfte zu erhöhen, indem man vermeidet, dass dort das Gefühl entsteht, im Zusammenhang mit der Software wird ihre alltägliche Arbeit kontrolliert.

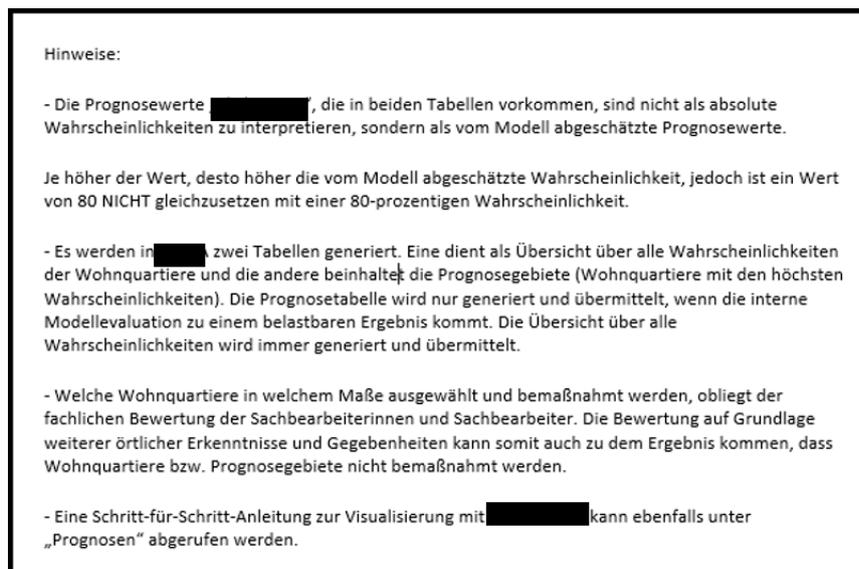
Auch wir können über die konkrete Umsetzung der Prognose auf der Straße und in den lokalen Behörden insgesamt noch nicht viel sagen. Trotzdem erlauben uns unsere bisherigen Einblicke, die von Esposito (2023) skizzierten Thesen zu algorithmischen Prognosen – Undurchsichtigkeit, Performativität, Individualisierung – auf unseren Fall zu beziehen.

## Rückbindung an Undurchsichtigkeitsthese

Eine der drei Thesen besagt, dass Prognosealgorithmen radikal undurchsichtig sein können (Esposito 2023, S. 1, i.O. mit Hervorh.). Sie sagt: „Algorithmische Prognosen [...] können radikal undurchsichtig sein: Angesichts der Anzahl der beteiligten Dimensionen und der Komplexität der Berechnungen können ihre Verfahren intransparent sein, unabhängig von der Kompetenz der Beobachter.“

Für unseren empirischen Fall haben wir in Bezug auf diese These bereits erste Entdeckungen machen können. Obgleich das zugrundeliegende Prädiktionsverfahren in den öffentlichen Dokumenten seitens der Polizei als besonders transparent dargestellt wird, da mit konkret benennbaren Kriminalitätstheorien und Daten gearbeitet wird, haben wir in der Praxis doch festgestellt, dass innerhalb des Teams der Forschungsstelle einige Unklarheiten herrschen, wie die Prognose konkret generiert wird.

Dazu ein konkretes Beispiel aus unseren Daten: Wie oben bereits beschrieben ist der Kern der Prognose der Prognosewert, der in den Excel-Tabellen erscheint. Wenn die Prognosewerte am Montagmittag auf den Server der Polizei hochgeladen werden, wird, wie erwähnt, eine E-Mail verschickt. Den Großteil der E-Mail nimmt ein Textblock ein, in dem erklärt wird, was der Prognosewert ist – oder genauer: was er nicht ist (vgl. Abb. 1). Der Wert repräsentiert laut dieser E-Mail keine „absolute Wahrscheinlichkeit“ sondern einen „abgeschätzte(n) Prognosewert“, was sich aus unserer Sicht tautologisch liest. Jedenfalls bleibt unklar, wo genau der Unterschied zwischen beiden liegen soll. Weiter unten lesen wir dann, dass die „echten“ Prognosen nur übermittelt werden, wenn die „Modellevaluation zu einem belastbaren Ergebnis kommt“. Wahrscheinlichkeiten werden also nicht primär dadurch zu Prognosen, dass sie einen konkreten Grenzwert überschreiten, sondern dadurch, dass die Modellevaluation die Datengrundlage für ausreichend belastbar hält.



**Abbildung 1: Email zur Bekanntgabe der neuen Prognosen (Auszug)**

Wir haben das im Feld nicht direkt verstanden. Als wir das thematisieren, kam auch von unseren Gesprächspartner:innen oft die Aussage: „Auch ich verstehe jetzt nicht so genau, was dieser Score sagt und wie er zustande kommt“. Immer wieder wurden wir auf eine der Data Scientists verwiesen, die diesen Score entwickelt hat, die an dem Tag allerdings für uns nicht zu erreichen war.

Wir können also festhalten: Für die Mitglieder der Forschungsstelle, mit denen wir bisher gesprochen haben, ist der Prognosewert im Detail durchaus undurchsichtig. Auch für die Polizist:innen in den lokalen Behörden, so wird zumindest in der Forschungsstelle angenommen, ist er undurchsichtig. Daher gibt es ja den zitierten Textblock in der E-Mail. Ist die Entwicklerin des Modells bzw. des Scores womöglich die einzige, die den Score erläutern kann?

## Rückbindung an Performativitätsthese

Die zweite der drei von Esposito (2023, S. 1) genannten Thesen besagt, dass algorithmische Prognosen performativ sind: „[S]ie verinnerlichen und nutzen die Zirkularität der *self-fulfilling* (oder *self-defeating*) *prophecies* [...]: die Vorhersagen produzieren die Zukunft, die sie vorhersagen“.

In Bezug auf Predictive Policing scheint diese These besonders plausibel für personenbezogenes Predictive Policing (Sommerer 2020; Egbert 2023). Das ist indes zu unterscheiden vom ortsbezogenen Predictive Policing, das wir uns ansehen. Beim personenbezogenen Predictive Policing werden Kriminalitätsrisiken für Individuen berechnet. Polizeihandeln orientiert sich dann an diesen personenbezogenen Prognosen. Beispielsweise werden Menschen mit hohem Risikoscore gezielt aufgesucht und mit einer „Gefährderansprache“ konfrontiert, wie z. B. in Chicago bei der Umsetzung der Strategie Subject List (SSL), mit dem Ziel, geneigte Täter:innen durch die persönliche – und ggf. strenge – Ansprache abzuschrecken (Saunders et al. 2016; Heimstädt et al. 2021).

Beim personenbezogenen Predictive Policing ist also die von Esposito (2023, S. 1) erwähnte *self-defeating prophecy* als eine Spielart der prognostischen Performativität erwünscht – mehr noch: Sie ist Ziel des ganzen Prozederes. Durch gezielte präventive Maßnahmen, die in der Regel auf Abschreckung aus sind, sollen algorithmisch identifizierte Risikopersonen daran gehindert werden, ihr Risiko

gleichsam auszuleben. Kritiker:innen des personenbezogenen Predictive Policing argumentieren jedoch, dass in Wirklichkeit eine andere Spielart prognostischer Performativität, nämlich die *self-fulfilling prophecy*, stattfindet. Denn dadurch, dass einzelne Menschen intensiver von der Polizei beobachtet werden, nimmt die Polizei zwangsläufig mehr kriminelle Aktivitäten dieser Personen wahr. Dies kann dazu führen, dass das Kriminalitätsrisiko, was für eine Person prognostiziert wurde, gerade durch die an die Prognose anschließenden polizeilichen Maßnahmen verstärkt, gleichsam hergestellt wird (Ensign et al. 2017; O’Neil 2016; Saunders et al. 2016).

Wie stellt sich Performativität aber nun in unserem Fall des ortsbezogenen Predictive Policing dar? Über die tatsächliche Nutzung der Prognosen auf der Straße können wir bisher noch nicht viel sagen. Aber zumindest in der offiziellen Darstellung des Landeskriminalamtes wird Predictive Policing als *self-defeating prophecy* erzählt: Polizist:innen fahren in prognostizierten Risikogebieten verstärkt Streife und schrecken durch ihre Präsenz potenzielle Einbrecher:innen ab. Der Unterschied zu personenbezogenem Predictive Policing besteht mit Blick auf prädiktive Performativität nun darin, dass hier keine *self-fulfilling prophecy* möglich ist. Denn die prognostizierten Taten – vor allem der Wohnungseinbruchdiebstahl – werden in aller Regel von den Einbruchsoffern angezeigt. Deren Anzeigebereitschaft hängt aber wiederum nicht mit der Präsenz von Streifenkräften vor Ort zusammen. Gleichzeitig werden in die Prognoseerstellung nur Daten zum Wohnungseinbruchdiebstahl integriert, nicht jedoch zu anderen Delikten, die möglicherweise durch polizeiliche Präsenz vor Ort mit größerer Wahrscheinlichkeit entdeckt wird. Das bedeutet, dass die Einbruchsprognose in unserem empirischen Fall nicht dazu führen kann, dass die Wahrscheinlichkeit steigt, dass die Polizei, die auf Grund der Prognosen öfters vor Ort ist, einen Einbruch registriert. Nur dann läge aber das Potenzial einer *self-fulfilling prophecy* durch raumbezogenen Kriminalitätsprognosen vor (ausführlich dazu: Egbert und Mann 2021).

Ortsbezogenes Predictive Policing ist somit, wenn es um Performativität geht, vor allem durch *self-defeating prophecies* charakterisiert. In diesem Sinne entfaltet es einen „präemptiven“ Effekt (Esposito 2021, S. 536), da Verhaltensweisen in der Zukunft durch die Prognosen gehemmt bzw. gänzlich blockiert werden. Und dieser präemptive Effekt ist nicht nur für die anvisierten Täter:innen möglich, die in ihrem Einbruchshandeln durch gezielte Polizeipräsenz abgeschreckt werden sollen. Er kann auch Unbeteiligte treffen – beispielsweise indem erhöhte Polizeipräsenz Kriminalitätsängste schürt, die zu Vermeidungsverhalten führen –, betrifft in jedem Falle aber auch die Polizei selbst. Denn auch Polizist:innen können nur an einem Ort gleichzeitig sein. Schickt die Prognose sie in ein bestimmtes Wohngebiet, um dort Präsenz zu zeigen, werden sie nicht in der Lage sein, Einbrecher:innen in einem anderen Areal, wo sie womöglich hingefahren wären, hätte es keine Prognose gegeben, in flagranti zu erwischen oder abzuschrecken.

## Rückbindung an Individualisierungsthese

Die dritte These von Esposito (Esposito 2023, S. 1, i. O. m. Hervorh.) besagt, dass algorithmische Prognosen „individuelle Ergebnisse von Fall zu Fall, mit Bezug auf das jeweilige *dataset*“ liefern. Wie die herkömmliche Statistik, so die These, rekurren die algorithmischen Prognosen also nicht mehr auf Durchschnittswerte und fokussieren auch nicht mehr primär auf Populationen.

Wie wir sehen, ist diese These sehr plausibel im Bereich der algorithmischen Prognostik in der Medizin (Hofmann 2023) und der Versicherung (Cevolini 2023). Für die Polizeiarbeit ist der Fall jedoch weniger klar bzw. er stellt sich dort anders dar. Naheliegenderweise kommt einem bei der Verbindung von Predictive Policing und der Individualisierungsthese zuerst das personenbezogene Predictive Policing in den Sinn (Sommerer 2020; Egbert 2023). Darauf wollen wir allerdings an dieser Stelle nicht weiter drauf

eingehen, sondern uns auf unseren empirischen Fall konzentrieren und mithin auf die Frage, ob die Individualisierungsthese sich auch auf ortsbezogene Kriminalitätsvorhersagen und deren Umsetzung übertragen lässt.

Ob durch algorithmische Prognosen in unserem Fall eine Individualisierung stattfindet, hängt dann vor allem davon ab, was man als „individuelles Ergebnis“, was man als Durchschnittswert und was man als Population begreift. Im Fall des Wohnungseinbruchsdiebstahls scheint klar: Der Einzelfall ist der Haushalt (ob jetzt in einem Einfamilienhaus oder in einer Wohnung). Aber was ist die hier relevante Population? Die Population könnte die Gesamtheit aller Haushalte in einer Stadt sein. Oder aber die Gesamtheit aller Haushalte eines bestimmten Typs (z.B. Einfamilienhäuser). Oder es könnten alle Haushalte in einem Stadtteil oder Einzugsgebiet einer bestimmten Polizeidienststelle sein. Was wir bisher aus unserer Forschung sagen können, ist, dass das Zustandekommen algorithmischer Prognosen bei der Polizei eng mit der Größe der referenzierten Wohngebiete zusammenhängt. Die Polizist:innen, mit denen wir gesprochen haben, betonten immer wieder, dass viel mit dem Zuschnitt dieser Gebiete experimentiert wurde, damit auch umsetzbare Prognosen entstehen – die z. B. nicht zu groß sein dürfen, weil sie dann nicht sinnvoll begreifbar sind, aber auch nicht zu klein, da die prognostische Qualität dann womöglich das notwendige Mindestmaß unterschreitet. Es ist zu diesem Zeitpunkt unklar, welche räumliche Bezugsgröße vor Predictive Policing für die Planung der Streifenfahrten genutzt wurde. Aber wir vermuten, dass das Wohngebiet, wie es für Predictive Policing als Referenz genutzt wird, deutlich kleiner ist. Die Individualisierungsthese scheint somit in gewisser Weise zuzutreffen – allerdings macht es Sinn, in unserem Fall eher von Granularisierung denn Individualisierung zu sprechen, da eben keine Individuen fokussiert werden.

Auch mit Bezug auf die These, dass durch die algorithmische Prognose nun keine Durchschnittsberechnung mehr stattfindet, können wir zum jetzigen Zeitpunkt noch keine definitive Antwort geben. Dies vor allem deshalb, da auch hier noch weitestgehend unklar ist, ob und wie Einbruchsriskien vor Predictive Policing berechnet wurden. Fakt ist aber, dass in dem von uns beobachteten Predictive-Policing-Fall keine klassische Durchschnittsberechnung zum Kriminalitätsrisiko eines Wohngebiets durchgeführt wird. Dies würde nämlich bedeuten, dass z. B. für eine gewisse Auswahl an Wohngebieten gleichen Typs – z. B. mit ähnlicher sozio-ökonomischer Zusammensetzung oder vergleichbarer Infrastruktur – in einem bestimmten Referenzzeitraum ein durchschnittliches Einbruchsrisiko ermittelt wird, was dann für alle Wohnquartiere dieses Typs gilt. Dies findet in unserem Falle aber nicht statt, da das Einbruchsrisiko stets für jedes Wohngebiet einzeln und gemäß der jeweils für das Wohnquartier gültigen Daten zum vergangenen Einbruchsaufkommen und zu den sozioinfrastrukturellen Begebenheiten separat berechnet wird.

## Fazit und Ausblick

Wir stehen noch am Anfang unserer Erhebung und es scheint bisher noch nicht möglich, die – wie der Projekttitel andeutet – gesellschaftlichen Folgen der algorithmischen Vorhersage in der Polizeiarbeit vollumfänglich zu bestimmen. Jedoch konnten wir bereits anhand der drei von Esposito (2023) präsentierten Thesen sowohl vorläufige Gemeinsamkeiten als auch Unterschiede zu den anderen beiden Teilprojekten zu den Themen Versicherung (Cevoloni 2023) und Medizin (Hofmann 2023) identifizieren. Während sich die Undurchsichtigkeitsthese bislang als zutreffend erweist, ist dies auch im Falle der Performativitätsthese – mit Blick auf *self-defeating prophecies* – der Fall. Bezüglich der Individualisierungsthese zeigt sich indes, dass diese bisher nur teilweise belegbar ist, wobei sich im weiteren Verlauf der empirischen Erhebung noch herausstellen muss, wie stark die raumzeitliche Fokussierung durch die

Prognosesoftware tatsächlich im Vergleich zu bisherigen polizeilichen Praktiken in diesem Bereich, im Sinne einer Granularisierung, zunimmt.

## Literatur

- Bennett Moses, Lyria, und Janet Chan. 2018. Algorithmic prediction in policing: Assumptions, evaluation, and accountability. *Policing and Society* 28:806–822.
- Brayne, Sarah. 2017. Big Data surveillance: The case of policing. *American Sociological Review* 82:977–1008.
- Brayne, Sarah. 2021. *Predict and surveil: Data, discretion, and the future of policing*. New York, NY: Oxford University Press.
- Cevolini, Alberto. 2023. Personalisierte Versicherung. In *Polarisierte Welten. Verhandlungen des 41. Kongresses der Deutschen Gesellschaft für Soziologie 2022*, Hrsg. Paula-Irene Villa Braslavsky. [https://publikationen.sozioogie.de/index.php/kongressband\\_2022](https://publikationen.sozioogie.de/index.php/kongressband_2022)
- Egbert, Simon. 2023. Social Sorting on Steroids? Die Gesellschaftlichen Risiken des Personenbezogenen Predictive Policing. In *Automatismen des Verdachts: Polizeikultur und Prognose in der Migrationsgesellschaft*, Hrsg. Georgiana Banita. Frankfurt am Main; New York: Campus (im Erscheinen).
- Egbert, Simon, und Maximilian Heimstädt. 2023. Algorithmic chains of translation: Predictive policing and the need for team-based ethnography. Routledge. In *Situated AI – Global Ethnographies of New Technologies in Policing and Justice.*, Hrsg. Maya Avis, Daniel Marciniak und Maria Sapignoli. Abingdon; New York: Routledge (im Erscheinen).
- Egbert, Simon, und Karolin Kornehl. 2022. Kommerzielle Software vs. Eigenentwicklung. Verbreitung und Ausgestaltung von Predictive Policing in Deutschland. *Kriminologisches Journal* 54:83–107.
- Egbert, Simon, und Susanne Krasmann. 2020. Predictive policing: not yet, but soon preemptive? *Policing and Society* 30: 905–919.
- Egbert, Simon, und Matthias Leese. 2021. *Criminal Futures: Predictive Policing and Everyday Police Work*. 1. Aufl. London & New York: Routledge.
- Egbert, Simon, und Monique Mann. 2021. Discrimination in Predictive Policing: The (dangerous) myth of impartiality and the need for STS Analysis. In *Automating Crime Prevention, Surveillance, and Military Operations*, Hrsg. Aleš Završnik und Vasja Badalič, 25–46. Cham: Springer International Publishing.
- Ensign, Danielle, Sorelle A. Friedler, Scott Neville, Carlos Scheidegger und Suresh Venkatasubramanian. 2017. Runaway feedback loops in Predictive Policing. *arXiv:1706.09847 [cs, stat]*.
- Espósito, Elena. 2023. Die Zukunft der Prädiktion. Einführung. In *Polarisierte Welten. Verhandlungen des 41. Kongresses der Deutschen Gesellschaft für Soziologie 2022*, Hrsg. Paula-Irene Villa Braslavsky. [https://publikationen.sozioogie.de/index.php/kongressband\\_2022](https://publikationen.sozioogie.de/index.php/kongressband_2022).
- Espósito, Elena. 2021. Unpredictability. In *Uncertain Archives*, Hrsg. Nanna Bonde Thylstrup, Daniela Agostinho, Annie Ring, Catherine D'Ignazio und Kristin Veel, 533–540. Cambridge: The MIT Press.
- Ferguson, Andrew G. 2017. *The rise of big data policing: Surveillance, race, and the future of law enforcement*. New York: New York University Press.
- Hardyns, Wim, und Anneleen Rummens. 2018. Predictive Policing as a new tool for law enforcement? Recent developments and challenges. *European Journal on Criminal Policy and Research* 24:201–218.
- Heimstädt, Maximilian, Simon Egbert und Elena Espósito. 2021. A pandemic of prediction: On the circulation of contagion models between public health and public safety. *Sociologica* 14:1–24.
- Hofmann, Dominik. 2023. Prädiktion in der Präzisionsmedizin. In *Polarisierte Welten. Verhandlungen des 41. Kongresses der Deutschen Gesellschaft für Soziologie 2022*, Hrsg. Paula-Irene Villa Braslavsky. [https://publikationen.sozioogie.de/index.php/kongressband\\_2022](https://publikationen.sozioogie.de/index.php/kongressband_2022)
- Kaufmann, Mareile, Simon Egbert und Matthias Leese. 2019. Predictive Policing and the politics of patterns. *The British Journal of Criminology* 59:674–692.

- O'Neil, Cathy. 2016. *Weapons of math destruction: How big data increases inequality and threatens democracy*. First edition. New York: Crown.
- Ratcliffe, Jerry H., Ralph B. Taylor und Ryan Fisher. 2020. Conflicts and congruencies between predictive policing and the patrol officer's craft. *Policing and Society* 30:639–655.
- Sandhu, Ajay, und Peter Fussey. 2021. The 'uberization of policing'? How police negotiate and operationalise predictive policing technology. *Policing and Society* 31:66–81.
- Saunders, Jessica, Priscillia Hunt und John S. Hollywood. 2016. Predictions put into practice: a quasi-experimental evaluation of Chicago's predictive policing pilot. *Journal of Experimental Criminology* 12:347–371.
- Sommerer, Lucia M. 2020. *Personenbezogenes Predictive Policing: kriminalwissenschaftliche Untersuchung über die Automatisierung der Kriminalprognose*. 1. Auflage. Baden-Baden: Nomos.
- Strikwerda, Litska. 2021. Predictive policing: The risks associated with risk assessment. *The Police Journal: Theory, Practice and Principles* 94:422–436.
- Waardenburg, Lauren, Marleen Huysman und Anastasia V. Sergeeva. 2022. In the land of the blind, the one-eyed man is king: Knowledge brokerage in the age of learning algorithms. *Organization Science* 33:59–82.
- Wilson, Dean. 2017. Algorithmic patrol. The futures of predictive policing. In *Big Data, Crime and Social Control*, Hrsg. Aleš Završnik, 108–127. Abingdon/New York: Routledge.