

Predictieve analyse in de criminologie

WIM HARDYNS^a

ANNELEEN RUMMENS^b

^a Docent, Institute for International Research on Criminal Policy (IRCP), Vakgroep Criminologie, Strafrecht en Sociaal Recht, Universiteit Gent en gastdocent, Faculteit Rechten, Universiteit Antwerpen (Corresp.: wim.hardyns@ugent.be).

^b Wetenschappelijk medewerker, Institute for International Research on Criminal Policy (IRCP), Vakgroep Criminologie, Strafrecht en Sociaal Recht, Universiteit Gent.

INLEIDING

Binnen het brede spectrum van kwantitatieve onderzoeksmethoden zien we de laatste jaren een sterke opmars van diverse voorspellingstechnieken, ook wel predictieve analysetechnieken genoemd. In deze rubriektekst willen we dieper ingaan op de betekenis van predictieve analyse, en in het bijzonder wat deze techniek zou kunnen betekenen voor een discipline zoals de criminologie. Eerst bespreken we wat predictieve analyse precies inhoudt. Vervolgens bekijken we hoe deze techniek kan toegepast worden binnen de criminologie. Tot slot gaan we dieper in op de verschillende stappen die men moet doorlopen om een predictief model te laten werken.

1. WAT IS PREDICTIEVE ANALYSE?

De opmars van predictieve analysetechnieken kunnen we kaderen binnen de exponentiële groei en toepassingen van *big data*. *Big data* verwijst naar datasets die een (extreem) groot volume hebben en verschillende bronnen of informatieniveaus samenbrengen, die diverse en gedetailleerde variabelen bevatten (zie bijvoorbeeld KITCHIN, 2014a voor meer informatie). We spreken met andere woorden over complexe datasets, bestaande uit duizenden tot zelfs miljoenen cases en honderden verschillende variabelen. Alhoewel deze kenmerken de analyse van *big data* tijdsintensief en complex maken, geeft dit de mogelijkheid belangrijke nieuwe bronnen van kennis en informatie te ontsluiten, die ons op hun beurt kunnen informeren over toekomstige patronen van datgene wat we willen bestuderen.

Om deze kennis te verkrijgen, zijn de reguliere methoden niet altijd toereikend en is er nood aan nieuwe methoden die in staat zijn met dergelijke datasets om te gaan. Bovendien is er ook de trend om proactiever om te gaan met die data, bijvoorbeeld door op predictie gerichte analyses uit te voeren, in plaats van louter de bestaande patronen te beschrijven of te verklaren. Bovenstaande heeft geleid tot de ontwikkeling van predictieve analysetechnieken. Predictieve analyse kan algemeen gedefinieerd worden als de analyse van een grote hoeveelheid historische data, met behulp van (vaak complexe) statistische modellen, met als doel te anticiperen op toekomstige gebeurtenissen (KUHN & JOHNSON, 2016), wat moet toelaten de beschikbare middelen proactief en dus efficiënter in te zetten. Predictieve analyse is in feite een koepelbegrip voor verscheidene statistische technieken, hoofdzakelijk gekenmerkt door complexe algoritmes op basis van zelflerende modellen, zoals neurale netwerken. Hoewel meer klassieke technieken, zoals logistische regressie, ook kunnen worden ingezet voor predictieve analyse, voor zover het classificatieprobleem niet te complex is, zijn deze minder in staat om te gaan met grote hoeveelheden indicatoren of complexe relaties tussen de verschillende variabelen.

Predictieve analyse wordt vandaag reeds uitgebreid toegepast in verschillende domeinen, bijvoorbeeld financiën en marketing. Een van de meest gebruikte toepassingen is het voorspellen van het klantenverloop, waarbij een bedrijf op basis van de beschikbare gegevens in het klantenbestand tracht te voorspellen welke klanten op het punt staan te vertrekken. Deze klanten kunnen vervolgens verleid worden met bijvoorbeeld een speciale promotie om alsnog bij het bedrijf in kwestie te blijven. Een andere veel gebruikte toepassing vinden we terug onder de vorm van advertenties en aanbevolen producten via websites zoals Amazon, Netflix en Facebook. Deze worden bepaald aan de hand van de voorspelde interesses van de bezoeker, op basis van data die deze websites kunnen en mogen verzamelen. En zo zijn er nog tal van andere voorbeelden van situaties waarin predictieve analyse vandaag succesvol wordt ingezet (zie SIEGEL, 2013), zoals het bepalen van risicoprofielen (bijvoorbeeld in het kader van een lening bij de bank), het detecteren van fraude, enzovoort¹.

2. CRIMINOLOGISCHE TOEPASSINGEN OP BASIS VAN PREDICTIEVE ANALYSE

De verzameling en analyse van *big data* heeft onvermijdelijk ook een impact op de sociale en humane wetenschappen in het algemeen (KITCHIN, 2014b) en de criminologie in het bijzonder (CHAN & MOSES, 2015). Binnen de context van criminaliteitsanalyse, kan de (steeds groter wordende) hoeveelheid aan criminaliteitsgegevens in politiedatabanken beschouwd worden als een waardevolle bron van *big data*, die gebruikt kan worden om nieuwe inzichten en kennis over huidige en opkomende criminaliteitstrends te verkrijgen. Hiervoor maakte men tot voor kort voornamelijk gebruik van exploratieve technieken, bijvoorbeeld clusteranalyse of netwerkanalyse (zie bijvoorbeeld CHEN e.a., 2004), om de belangrijkste patronen te beschrijven en te visualiseren. Om effectief criminaliteit te kunnen voorspellen in tijd en ruimte, wordt deze manier van werken echter als té retrospectief beschouwd, in die zin dat patronen uit het verleden enkel beschreven worden en zonder meer geëxtrapoleerd worden naar het heden (GROFF & LA VIGNE, 2002). Predictieve analyse biedt hier een alternatief door prospectief-gerichte analyses mogelijk te maken en bijgevolg proactiever te kunnen omgaan met deze informatie.

Vandaag kennen we reeds een aantal concrete criminologische toepassingen die gebruik maken van predictieve analyse. Ze zijn gebaseerd op de statistische analyse van meestal grote hoeveelheden data en ze dienen om te anticiperen op nieuwe criminele feiten of fenomenen (BACHNER, 2013; McCUE, 2015; PERRY e.a., 2013). PERRY e.a. (2013) maken een onderscheid tussen het gebruik van predictieve analyse voor (1) het voorspellen van daders, (2) het voorspellen van slachtoffers, en (3) het voorspellen van waar en wanneer er een hoog risico is op nieuwe criminele feiten.

De eerste categorie betreft bijvoorbeeld het voorspellen van het risico op recidive (bijvoorbeeld BERK e.a., 2009) of het identificeren van mogelijke verdachten op basis van hun achtergrondgegevens en kenmerken van bepaalde misdrijven. Predictieve analyse gaat hier hand in hand met andere technieken zoals dader- en geografische profilering.

De tweede categorie richt zich bijvoorbeeld op het voorspellen van risicogroepen aan de hand van slachtofferkenmerken of het voorspellen van het risico op (escalering van) huishoudelijk geweld of bendege geweld (bijvoorbeeld RATCLIFFE & RENGERT, 2008).


¹ Toch is het gebruik van predictieve analyse niet altijd even succesvol, bijvoorbeeld omdat de toepassing controversieel is omwille van de vertrouwelijke informatie die nodig is (bijvoorbeeld in de gezondheidszorg, zie COHEN e.a., 2014) of omdat het moeilijk blijkt om betrouwbare indicatoren te identificeren of er data over te verzamelen (bijvoorbeeld bij het voorspellen van aardbevingen, zie SILVER, 2012).

Bij de derde categorie wordt getracht om toekomstige misdrijven zo nauwkeurig mogelijk te voorspellen in tijd en ruimte om op basis daarvan politiepatrouilles proactief te kunnen aansturen. Deze toepassing wordt ook wel aangeduid met de Engelse term *predictive policing* (RATCLIFFE, 2014). De laatste jaren is men wereldwijd gestart met het introduceren van deze toepassing binnen diverse politiediensten (zie HARDYNS & RUMMENS, 2016 voor een uitgebreide discussie).

Het potentieel om criminaliteit te voorspellen volgt uit de empirische observatie dat criminaliteit niet willekeurig plaatsvindt, maar dat er contextuele factoren zijn die criminaliteitsopportuniteiten creëren en beïnvloeden (BRANTINGHAM, 2013; ECK & WEISBURD, 2015; KINNEY e.a., 2008). Deze indicatoren kunnen geïdentificeerd worden en dienen om potentiële risicolocaties, daders of slachtoffers te voorspellen. Predictieve analyse is echter niet geschikt ter verklaring van die criminaliteitsfenomenen of kan niet ingezet worden in het kader van een duurzame en structurele preventie. In dat opzicht dient predictieve analyse steeds als een complementair instrument beschouwd te worden, dat zijn plaats heeft naast de meer traditionele kwantitatieve onderzoekstechnieken.

3. HOE WERKT PREDICTIEVE ANALYSE?

Wanneer we bovenstaande toepassingen willen hanteren, kunnen we grosso modo drie belangrijke stappen onderscheiden bij het ontwikkelen van een predictief model: (1) de dataverzameling, (2) de statistische modellering, en (3) de interpretatie en evaluatie van de resultaten (zie figuur 1).



Figuur 1. De verschillende stappen bij de toepassing van predictieve analyse

3.1 Dataverzameling

De eerste belangrijke stap is het verzamelen van datamateriaal. Zoals eerder vermeld, werkt predictieve analyse op basis van grote hoeveelheden historische data. Predictieve analysetechnieken zijn in de eerste plaats bedoeld om grote hoeveelheden data aan te kunnen, maar hebben die grote hoeveelheid data ook nodig om effectief te zijn. Immers, hoe meer associaties er kunnen gemaakt worden tussen de indicatorvariabelen (kenmerken die men gebruikt om iets te kunnen voorspellen) en de uitkomstvariabelen (wat men uiteindelijk

probeert te voorspellen, bijvoorbeeld het risico op nieuwe criminele feiten), hoe beter het model de verschillende mogelijke patronen en de associaties tussen de verschillende indicatoren leert kennen. Welke data verzameld moeten worden en welke stappen moeten gezet worden in het kader van datapreparatie is afhankelijk van de concrete toepassing (zie supra) waarvoor predictieve analyse wordt ingezet.

Aangezien de voorspellingen gebaseerd worden op historische data, is de datakwaliteit uiteraard van groot belang. Hoe preciezer en accurater deze data, hoe kwaliteitsvoller de resulterende voorspellingen zullen zijn. Een kwaliteitsevaluatie van de te gebruiken data is dus steeds noodzakelijk. In het geval van criminaliteitsanalyses zullen deze kwaliteitscriteria bijvoorbeeld bepalen welke delicten al dan niet geschikt zijn voor predictieve analyse: minder geschikte delicten hebben ofwel een lage frequentie en leveren dus niet genoeg data, of ze hebben een lage aangiftebereidheid wat ervoor kan zorgen dat de voorspellingen verstoord worden. Delicten met persoonlijke motieven zijn bijvoorbeeld ook minder geschikt, aangezien er minder voor de hand liggende meetbare indicatoren kunnen gevonden worden dan bij delicten waar dader en slachtoffer elkaar niet kennen (en er meer rationele motieven aan ten grondslag liggen).

De vraag kan ook gesteld worden hoever men moet teruggaan in de tijd en hoeveel kenmerken men dient toe te voegen om tot succesvolle voorspellingen te kunnen komen. Voorgaand onderzoek heeft aangetoond dat we een logaritmische relatie² kunnen verwachten tussen de lengte van de historische tijdsspanne waarvoor data verzameld is en de voorspellingsprestaties, wat wil zeggen dat het toevoegen van bijkomende jaren aan historische data in het begin een grote winst in voorspellingprestaties met zich meebrengt, maar dat deze winst zich uiteindelijk zal uitvlakken zodanig dat het blijven toevoegen van historische data geen meerwaarde meer heeft in functie van het verbeteren van de voorspellingen. Hier zijn twee redenen voor: in de eerste plaats zijn de meest recente data vaak het meest informatief voor de toekomstige patronen. De meest recente data krijgen vandaar vaak ook meer gewicht bij de analyse. Ten tweede zal het gebruik van een steeds langere historische tijdsspanne uiteindelijk ook meer ruis introduceren, wat wil zeggen dat een steeds groter wordend deel van de data eigenlijk geen nieuwe informatie meer levert over de associatie tussen de indicatoren en de uitkomstvariabele. Verder onderzoek moet uitwijzen wat bijvoorbeeld de ideale historische tijdsspanne is waarmee men moet rekening houden in het kader van criminaliteitsvoorspellingen.

3.2 Statistische modellering

De tweede stap is statistische modellering van de in de eerste stap verzamelde historische data (zie supra). We kunnen een onderscheid maken tussen twee types modellen: (1) de klassieke statistische modellen (bijvoorbeeld logistische regressie) en (2) zelflerende modellen (bijvoorbeeld neurale netwerken). De combinatie van meerdere modellen, ook wel *ensemble-modellering* genoemd, behoort ook tot de mogelijkheden.

De klassieke statistische modellen zijn reguliere kwantitatieve technieken die ook ingezet kunnen worden voor predictieve analyse. Het meest gebruikte model binnen deze categorie is logistische regressie. Logistische regressie is een standaard en relatief eenvoudig statistisch model dat gebruikt wordt voor classificatie in twee (of meer) groepen op basis van

2 Dit is nog niet empirisch vastgesteld voor criminologische toepassingen, maar wel in andere domeinen (zie bijvoorbeeld BALLINGS & VAN DEN POEL, 2012).

de waarden van de indicatorvariabelen (AGRESTI, 2013). Gebaseerd op de klassieke modellen werden ook een aantal modellen ontwikkeld specifiek voor concrete criminologische toepassingen (bijvoorbeeld WANG & BROWN, 2012). Zoals in het begin van deze rubriektekst aangegeven, zijn deze reguliere technieken minder bruikbaar wanneer men te maken heeft met complexe voorspellingen op basis van een grote hoeveelheid indicatoren.

Wanneer de klassieke modellen niet voldoen, kan geopteerd worden voor zogenaamde zelflerende modellen, die gekenmerkt worden door een hogere voorspellingskracht en betere voorspellingen opleveren wanneer we te maken hebben met complexe (uitgebreide) datasets (HAYKIN, 2009). Neurale netwerkmodellen zijn hier het typevoorbeeld. Dit type van modellen leert patronen te herkennen in de data en corrigeren zichzelf in iteratieve cycli op basis van gekende (historische) waarden voor de uitkomstvariabele. De structuur van dit type modellen kan beschouwd worden als een *black box*: men krijgt namelijk geen inzicht in de werkelijke relaties tussen de indicatorvariabelen en de uitkomstvariabele. Dit betekent in de praktijk dat ze wel een predictieve, maar geen verklarende waarde hebben (= een andere finaliteit dan de reguliere technieken). Het is dan ook moeilijker om te bepalen welke indicatoren het meest van invloed zijn op de uitkomstvariabele, bijvoorbeeld wanneer men minder relevante variabelen zou willen weren uit de analyse, terwijl dit bij een klassiek model zoals logistische regressie, wel mogelijk is. Bovendien bestaat er bij dit type van modellen gevaar voor *overfitting*, waarbij het model wel beter wordt in het voorspellen van de trainingsdata, maar slechter in het verwerken van nieuwe data. Om dit probleem op te vangen, wordt de verzamelde data gewoonlijk onderverdeeld in een trainings-, validatie- en testset (volgens een 70%-20%-10% verdeelsleutel). De trainingsset wordt hierbij gebruikt om het model te ontwikkelen ('trainen'), de validatieset om het model verder te verfijnen en de testset dient als ultieme test van het model. Op deze manier kan de werking van het model uiteindelijk beoordeeld worden op basis van ongebruikte (en idealiter onafhankelijke) data.

Aangezien zowel de klassieke als de zelflerende modellen elk hun eigen voor- en nadelen hebben, kan het nuttig zijn om combinaties te maken (*ensemble*-modellering). Empirisch onderzoek heeft aangetoond dat het combineren van modellen betere resultaten kan opleveren dan de deelmodellen afzonderlijk, gezien de sterktes van het ene model de zwaktes van het andere kunnen opvangen (ZHOU, 2012). Een mogelijke combinatie is bijvoorbeeld een logistisch regressiemodel met een neuraal netwerkmodel, waarbij de hogere stabiliteit van de logistische regressie gecombineerd kan worden met de hogere voorspellingskracht van het neurale netwerk.

3.3 Interpretatie en evaluatie van de resultaten

In de derde stap kunnen de resultaten van het model geïnterpreteerd en geëvalueerd worden. Dit gebeurt doorgaans door middel van een classificatietabel (zie tabel 1); een kruistabel waarbij de frequenties van de voorspelde waarden tegen de frequenties van de werkelijke waarden worden uitgezet. Hieruit kan op een eenvoudige manier afgeleid worden in welke mate de voorspellingen correct (Juist-positief en Juist-negatief) of foutief (Fout-positief en Fout-negatief) zijn.

Tabel 1. Structuur van een classificatietabel

Voorspelde situatie	Werkelijke situatie		
		Nieuwe criminele feiten	Geen nieuwe feiten
	Nieuwe criminele feiten	(Juist-positief)	(Fout-positief)
	Geen nieuwe feiten	(Fout-negatief)	(Juist-negatief)

De output van het model is telkens voor elke analyse-eenheid (bijvoorbeeld 'locaties' bij spatiotemporele predicties van criminaliteit) de statistische kans (probabiliteit) dat wat we trachten te voorspellen ook werkelijk plaatsvindt (bijvoorbeeld of nieuwe criminele feiten zullen plaatsvinden). De vraag stelt zich dan hoe hoog dat de probabiliteit moet zijn om er vanuit te gaan dat de voorspelde gebeurtenis zal plaatsvinden. Deze drempelwaarde (*cut-off*) kan bepaald worden met behulp van de *Receiver Operating Characteristic* (ROC) curve. De ROC-curve geeft de sensitiviteit weer in functie van de aspecificiteit. De sensitiviteit geeft de proportie correcte voorspellingen weer (ook wel trefkans of juist-positieven genoemd). De aspecificiteit geeft de proportie foute voorspellingen weer, die onterecht als hoog-risico aangemerkt werden ('vals alarm', ook wel fout-positieven genoemd). Gewoonlijk wordt een drempelwaarde met behulp van de ROC-curve gekozen die de verhouding tussen deze twee waarden maximaliseert (dus een zo hoog mogelijke trefkans ten opzichte van een zo laag mogelijk aandeel fout-positieven). Deze afweging tussen enerzijds een hoge trefkans en anderzijds zo weinig mogelijk fout-positieven is van groot belang bij het evalueren van de voorspellingskwaliteit. Het doel is uiteraard om zo veel mogelijk correcte voorspellingen te maken, maar een hoog aantal voorspellingen kan ook een hoog aantal fout-positieven met zich meebrengen. In de praktijk brengt een hoog aantal fout-positieven een hogere kost met zich mee, bijvoorbeeld door het onterecht inzetten van middelen of personeel bij het voorspellen van plaatsen waar criminaliteit zal optreden of bijvoorbeeld omwille van ethische bezwaren bij het voorspellen van daders. In die situaties kan het wenselijk zijn om conservatievere voorspellingen te maken en dus het laag houden van het aandeel fout-positieven te laten primeren. Het balanceren tussen deze afwegingen vinden we ook terug in de parameters die gebruikt worden voor het evalueren van de voorspellingskwaliteit.

Voor het evalueren van de voorspellingskwaliteit kunnen verschillende parameters gebruikt worden (zie tabel 2):

Tabel 2. Parameters voor het evalueren van de voorspellingskwaliteit

Parameter	Definitie
Trefkans	$\frac{\# \text{ juist-positieven}}{\# \text{ werkelijke feiten}}$
Precisie	$\frac{\# \text{ juist-positieven}}{\# \text{ juist-positieven} + \# \text{ fout-positieven}}$
Predictie-index	$\frac{\text{trefkans}}{\text{oppervlakte voorspeld risicogebied} / \text{totale oppervlakte onderzocht gebied}}$
ROC-AUC	oppervlakte onder de curve van de ROC-grafiek

(1) In de eerste plaats kan men kijken naar de de trefkans (aantal juist-positieven ten opzichte van het totale aantal werkelijk gebeurde feiten). Dit is de meest voor de hand lig-

gende maat, aangezien een van de hoofddoelen van predictieve analyse is om een zo hoog mogelijk aantal correcte voorspellingen te bereiken. Het kan echter in zekere zin ook een misleidend cijfer zijn, aangezien een verhoging van het totale aantal voorspellingen een artificiële verhoging van de trefkans met zich kan meebrengen. Om dit probleem op te vangen, wordt gewoonlijk ook gekeken naar de precisie van de voorspellingen.

(2) De precisie geeft het aantal correcte voorspellingen (juist-positieven) ten opzichte van het totale aantal hoog-risico voorspellingen (som van juist-positieven en fout-positieven) weer. Hoe hoger de precisie, hoe minder fout-positieven er zijn en hoe efficiënter de voorspellingen dus zijn. In de praktijk moet vaak een afweging gemaakt worden tussen een hogere trefkans of een hogere precisie. Denk bijvoorbeeld aan het extreme voorbeeld dat elke geanalyseerde eenheid als hoog-risico wordt aangemerkt: alhoewel de trefkans dan 100% is, hebben de resultaten geen praktische waarde meer wegens ontoereikende precisie.

(3) Voor spatiotemporele predicties van criminaliteit wordt er vaak ook gebruik gemaakt van predictie-indices die rekening houden met de spatiale dimensie, waarbij de relatieve oppervlakte van de voorspelde zone ten opzichte van de totale zone in overweging wordt genomen (bijvoorbeeld de *prediction accuracy index* van CHAINEY e.a., 2008). Hierbij wordt gestreefd naar een evenwicht tussen een hoge trefkans en een kleine voorspelde risicozone.

(4) Tot slot wordt ook de *Area Under the Curve* (AUC) van de ROC-curve gebruikt om predictieve modellen te evalueren. Dit wordt beschouwd als een neutralere maatstaf, want de ROC-AUC is onafhankelijk van de gekozen drempelwaarde. De ROC-AUC laat dus toe de predictieve analysemodellen te evalueren zonder dat de discriminatiedrempel bepaald moet worden. Het bovenstaande dilemma tussen een hogere trefkans of een hogere precisie wordt op die manier vermeden. De ROC-AUC is in het bijzonder geschikt om verschillende modellen met elkaar te vergelijken.

BESLUIT

Predictieve analysetechnieken berusten doorgaans op geavanceerde kennis met betrekking tot dataverwerking en -analyse. Criminologen die over de nodige statistische bagage beschikken, kunnen deze techniek in de toekomst ongetwijfeld inzetten in het kader van allerhande nieuwe toepassingen. Maar ook criminologen die uitsluitend over een basiskennis statistiek beschikken, kunnen door samen te werken met methodologen of statistici creatief op zoek gaan naar terreinen waarbinnen predicties een meerwaarde kunnen betekenen. De toepassing van predictieve analyse binnen de criminologie staat op dit moment echter nog in haar kinderschoenen en heeft dus nood aan meer empirisch en methodologisch onderzoek om het potentieel van predictieve analyse ten volle te kunnen benutten. De succesvolle toepassing van predictieve analyse kan immers een meerwaarde betekenen, die niet alleen een nieuwe bron van kennis ontsluit, maar ons ook toelaat proactiever om te gaan met deze kennis.

Niettemin zijn er ook enkele kritische kanttekeningen te maken bij het gebruik van predictieve analyse (HARDYNS & RUMMENS, 2016; SCHUILENBURG, 2016). De verzameling van grote hoeveelheden data (*big data*) door de overheid, maar ook door commerciële bedrijven, roept vragen op met betrekking tot de privacy. Ook het gebruik van predictieve analyse zelf houdt gevaren in. Zo kan de vraag gesteld worden of een voorspelling volstaat om bepaalde acties te ondernemen en of dit niet kan leiden tot een groter risico op etnische profilering of het verwaarlozen van basisbeginselen zoals het vermoeden van onschuld. Bovendien is er ook

het gevaar dat men te blind gaat vertrouwen op technische hulpmiddelen, zonder rekening te houden met de grenzen die eigen zijn aan de methodiek. Wil men deze technieken in de toekomst succesvol inzetten, zal men ook met deze uitdagingen moeten kunnen omgaan.

REFERENTIES

- AGRESTI, A. (2013). *Categorical data analysis* (3rd ed.). Wiley Series in Probability and Statistics. Hoboken, NJ: John Wiley & Sons.
- BACHNER, J. (2013). *Predictive policing: Preventing crime with data and analytics*. Improving Performance Series. Washington, DC: IBM Center for the Business of Government.
- BALLINGS, M. & VAN DEN POEL, D. (2012). Customer Event History for Churn Prediction: How Long is Long Enough? *Expert Systems with Applications*, 39(18), 13717-13522.
- BRANTINGHAM, P.J. (2013). The theory of target search. In F.T. CULLEN, & P. WILCOX (Eds.), *The Oxford handbook of criminological theory*. Oxford: Oxford University Press.
- BERK, R., SHERMAN, L., BARNES, G. KURTZ, E. & AHLMAN, L. (2009). Forecasting murder within a population of probationers and parolees: a high stakes application of statistical learning. *Journal of the Royal Statistical Society: Series A (Statistics in Society)*, 172(1), 191-211.
- CHANEY, S., TOMPSON, L., & UHLIG, S. (2008). The utility of hotspot mapping for predicting spatial patterns of crime. *Security Journal*, 21, 4-28.
- CHAN, J., & MOSES, L.B. (2015). Is big data challenging criminology? *Theoretical Criminology*, 20(1), 21-39.
- CHEN, H., CHUNG, W., XU, J.J., WANG, G., QIN, Y. & CHAU, M. (2004). Crime data mining: A general framework and some examples. *Computer*, 37(4), 50-56.
- COHEN, G., R. AMARASINGHAM, A. SHAH, B. XIE & LO, B. (2014). The Legal and Ethical Concerns that Arise from Using Complex Predictive Analytics in Health Care. *Health Affairs*, 33(7), 1139-1147.
- ECK, J.E., & WEISBURD, D.L. (2015). Crime places in crime theory. *Crime and Place: Crime Prevention Studies*, 4, 1-33.
- GROFF, E.R., & LA VIGNE, N.G. (2002). Forecasting the future of predictive crime mapping. *Crime Prevention Studies*, 13, 29-57.
- HARDYNS, W., & RUMMENS, A. (2016). Predictieve analyse voor politiediensten: Een kennismaking. *Handboek Politiediensten*, 119, 371-410.
- HAYKIN, S. (2009). *Neural networks and learning machines* (3rd ed.). New York: Pearson.
- KINNEY, J.B., BRANTINGHAM, P.L, WUSCHKE, K., KIRK, M.G., & BRANTINGHAM, P.J. (2008). Crime attractors, generators and detractors: Land use and urban crime opportunities. *Built Environment*, 34(1), 62-74.
- KITCHIN, R. (2014a). *The data revolution: Big data, open data, data infrastructures and their consequences*. London: Sage Publications.
- KITCHIN, R. (2014b). Big data, new epistemologies and paradigm shifts. *Big Data & Society*, 1(1), 1-12.
- KUHN, M. & JOHNSON, K. (2016). *Applied Predictive Modeling*. New York: Springer.
- McCUE, C. (2015). *Data mining and predictive analysis: Intelligence gathering and crime analysis* (2nd ed.). Oxford: Elsevier Science Publishing.
- PERRY, W.L., McINNIS, B., PRICE, C.C., SMITH, S.C., & HOLLYWOOD, J.S. (2013). *Predictive policing: The role of crime forecasting in law enforcement operations*. RAND Research Reports. Santa Monica: RAND Safety and Justice Program.
- RATCLIFFE, J. (2014). What is the future of... predictive policing? *Translational Criminology*, 6, 4-5.

- RATCLIFFE, J. & RENGERT, G.F. (2008). Near-Repeat Patterns in Philadelphia Shootings. *Security Journal*, 21, 58-76.
- SCHUILENBURG, M. (2016). Predictive Policing: De opkomst van een gedachtenpolitie? *Ars Aequi*, december, 931-936.
- SIEGEL, E. (2013). *Predictive analysis: The power to predict who will click, buy, lie or die*. Hoboken: John Wiley & Sons.
- SILVER, N. (2012). *The Signal and the Noise: The Art and Science of Prediction*. Londen: Penguin Books.
- WANG, X., & BROWN, D.E. (2012). The spatio-temporal modeling for criminal incidents. *Security Informatics*, 1(2), 1–17.
- ZHOU, Z.-H. (2012). *Ensemble methods: Foundations and algorithms*. Machine Learning and Pattern Recognition Series. Abingdon: CRC Press.