UvA-DARE (Digital Academic Repository)

De algoritmische waakhond

Datagedreven mededingingstoezicht

Sviták, J.; Brouwer, E.

DOI

[10.5553/TvT/187987052018009002005](https://doi.org/10.5553/TvT/187987052018009002005)

Publication date

2018

Document Version

Final published version

Published in

Tijdschrift voor Toezicht

[Link to publication](#)

Citation for published version (APA):

Sviták, J., & Brouwer, E. (2018). De algoritmische waakhond: Datagedreven mededingingstoezicht. *Tijdschrift voor Toezicht*, 9(2-3), 57-64.
<https://doi.org/10.5553/TvT/187987052018009002005>

General rights

It is not permitted to download or to forward/distribute the text or part of it without the consent of the author(s) and/or copyright holder(s), other than for strictly personal, individual use, unless the work is under an open content license (like Creative Commons).

Disclaimer/Complaints regulations

If you believe that digital publication of certain material infringes any of your rights or (privacy) interests, please let the Library know, stating your reasons. In case of a legitimate complaint, the Library will make the material inaccessible and/or remove it from the website. Please Ask the Library: <https://uba.uva.nl/en/contact>, or a letter to: Library of the University of Amsterdam, Secretariat, Singel 425, 1012 WP Amsterdam, The Netherlands. You will be contacted as soon as possible.

Uit het veld

De algoritmische waakhond

Datagedreven mededingingstoezicht

Jan Sviták en Erik Brouwer*

In dit artikel gaan wij in op de vraag hoe een mededingingsautoriteit datagedreven technieken kan inzetten om effectiever te worden. *Machine learning* is in de laatste jaren enorm populair geworden, levert vaak snel goede resultaten op en vormt de basis voor succes van vele *e-commerce*-bedrijven die (bijna) dagelijks *machine learning*-algoritmes toepassen om de optimale prijzen te bepalen van al hun producten, gegeven historische transacties die concurrenten aanbieden en gelet op de omvang van de eigen voorraad. *Machine learning* is echter alleen geschikt voor specifieke vraagstukken. Het verschil tussen causaliteit en voorspelkracht speelt daarbij een belangrijke rol. Vaak past een ‘ouderwetse’ statistische analyse beter bij de onderzoeksvraag over oorzaak en gevolg. Voorbeelden van nuttige toepassingen van *machine learning*-technieken zijn voorspellingsmodellen en verkennende data-analyse, die op nieuwe inzichten kan wijzen of bepaalde gebeurtenissen kan signaleren. Wij bespreken een simpel algoritme toegepast op detectie van veranderingen in prijsdata en laten zien hoe dit tijdrovende handmatige analyses kan vervangen. Een mededingingsautoriteit kan soortgelijke algoritmes als een belangrijke en noodzakelijke aanvulling gebruiken op de ‘ouderwetse’ maar eveneens nuttige statistische analyses voor o.a. opsporing van kartels. De methode is flexibel qua inzet in verschillende markten en toepassingen van diverse aannames over het gedrag van ondernemingen.

* Dhr. J. Sviták is econometrist bij het Economisch Bureau van de Autoriteit Consument en Markt en extern PhD student aan Tilburg University. Prof. Dr. E. Brouwer is clusterhoofd big data bij SEO Economisch Onderzoek en bijzondere hoogleraar mededinging en innovatie aan Tilburg University.

Introductie

De toenemende beschikbaarheid van data en reken capaciteit om grote hoeveelheden gegevens te verwerken biedt kansen om snel nieuwe inzichten te krijgen en deze efficiënt in te zetten. Ondanks het feit dat een term zoals ‘*Business Intelligence*’ kan suggereren dat deze ontwikkelingen vooral relevant zijn voor het bedrijfsleven, is dat zeker niet het geval. Wetenschappers hebben altijd veel gebruik gemaakt van data, maar ook overheidsinstellingen kunnen nieuwe inzichten uit data gebruiken in hun besluitvorming om beter geïnformeerde keuzes te (kunnen) maken.

Zo kan bijvoorbeeld met data worden geïdentificeerd wat de impact van verschillende fenomenen is op een relevante uitkomst, waardoor beleidsmakers in staat zijn om een maatregel te kiezen die dit mechanisme benut en de uitkomst efficiënt én op een gewenste manier beïnvloedt. Een onderzoek kan achterhalen aan de hand van data wat de effecten zouden zijn van een verbreding van een snelweg met een extra rijstrook op het ontstaan van (bij voorkeur) minder files, maar ook op bredere regionale economische omstandigheden.¹ Data over verkeersstromen, beschikbare banen en bevolkingsontwikkeling zijn voorbeelden van bronnen die kunnen worden gebruikt. De effecten kunnen dan worden vergeleken met die van het aanleggen van een nieuwe snelweg, en een goede kosten-batenanalyse kan dan worden uitgevoerd om te bepalen of en zo ja op welke manier er extra kilometers snelweg dienen te worden aangelegd.

Voorspellingsmodellen kunnen helpen bij de inschatting van relevante toekomstige ontwikkelingen. Nieuwe

1. Zie bijvoorbeeld I.V. Ossokina en A. Brouwer. ‘Investeren in infrastructuur’, *CPB Policy Brief* 2016, 6.

inzichten kunnen leiden tot tijdige introductie van nieuw beleid of aanpassing van huidige maatregelen. Nauwkeurige schatting helpt bovendien bij het bepalen van parameters van vrijwel alle beleidsstukken gericht op de toekomst.

Efficiënte bewerking van grote hoeveelheden gegevens kan helpen bij het detecteren van belangrijke gebeurtenissen. Zo kan bijvoorbeeld *machine learning* worden gebruikt voor het eerder identificeren van trends in meldingen van burgers, fraude of fouten bij betalingen van belastingen en toeslagen. Deze trends kunnen worden gedetecteerd en opvallende patronen in de data kunnen leiden tot nieuwe inzichten en snellere acties.

Niet alle tools zijn echter even krachtig en bruikbaar voor alle bovenstaande vraagstukken. In dit artikel waarschuwen we voor mislukkingen, die datagedreven werken met zich mee kan brengen als dit niet juist uitgevoerd is. Verder lichten wij toe waarom de focus op het doel van de analyse moet liggen en niet op een methode, ongeacht hoe populair deze methode is. Tot slot bespreken wij de relevantie van data-analyse voor mededingingsautoriteiten en bespreken wij een eenvoudig algoritme dat een mededingingsautoriteit kan inzetten voor het opsporen van kartels.

Kan het misgaan?

58

Termen als ‘*big data*’, ‘*data science*’ of ‘*machine learning*’ zijn de laatste jaren zeer populair en worden dan ook vaak gebruikt. Grotendeels is dat dankzij giganten zoals Google, Spotify en Facebook, die enorme hoeveelheden data en *machine learning*-technieken grootschalig inzetten om gedrag en voorkeuren van consumenten te kunnen voorspellen. Huidige softwarepakketten maken het bovendien mogelijk om met één druk op de knop een geavanceerd algoritme te draaien en een analyse uit te voeren. Dat is uiteraard heel efficiënt en biedt grote kansen, maar kan óók gevaarlijk zijn.

Alle *machine learning*-algoritmes, inclusief *state-of-the-art* kunstmatige intelligentie, zijn gebaseerd op statistiek en een groot aantal aannames. Niet elke methode is bruikbaar voor elke analyse en de analist moet dus goed weten wat er achter de schermen gebeurt. Een druk op de knop maakt de methoden uiteraard krachtig en gebruiksvriendelijk maar het gemak geeft de analist ook een prikkel om een diepgaande bestudering van de gebruikte methode over te slaan. Er bestaat dan een risico dat de resultaten verkeerd begrepen of geïnterpreteerd worden of zelfs foutief zijn voor de gewenste analyse. Zo is het bijvoorbeeld bij bepaalde modellen nodig om alle variabelen vooraf te standaardiseren zodat ze alle waarden op dezelfde schaal hebben. Mocht deze stap worden overgeslagen, dan heeft dat invloed op het resultaat en dat is uiteraard ongewenst.

Veel van de *machine learning*-methoden zijn ontwikkeld om voorspellingen te doen. Het doel van een typische *machine learning*-techniek is om met een model *als geheel* goed te voorspellen. Deze prestatie is ook wat geoptima-

liseerd wordt. Het is dus secundair of een bepaald *onderdeel* of variabele van een model op zichzelf juist is geschat en een realistische weergave van een gedeeltelijk effect biedt. Het effect van een bepaalde maatregel of het verband met een belangrijke indicator zijn echter juist typisch vraagstukken waarmee de overheidsinstellingen te maken hebben. Het onderscheid tussen correlatie en causaliteit is hier cruciaal. Terwijl correlatie voldoende is om goede voorspellingen te doen, is causaliteit van uiterst belang voor beleidsmakers, die met een maatregel een bepaalde ontwikkeling in gang willen zetten of conclusies willen trekken over oorzaken van concrete ongewenste fenomenen of de impact van beleidsmaatregelen..

Dit betekent niet dat *machine learning*-technieken niet toegepast kunnen worden bij een onderzoek naar causale verbanden, maar dat de juistheid van de eventuele toepassing niet vanzelfsprekend is. Er moet zorgvuldig worden nagedacht over de voor- en nadelen van bepaalde technieken en een analist moet niet worden afgeleid door de dorst naar toepassingen van methoden met hippe namen. Een ‘oude’ methode, die ontwikkeld is voor oplossing van het causaliteitsprobleem, is in vele gevallen beter dan een kortzichtige vervanging ervan door een moderne methode ontwikkeld puur voor een voorspelling. Het is dus belangrijk om te focussen op data én data-analyse in alle vormen en smaken, en niet alleen op één gedeelte ervan. De nadruk moet dus worden gelegd op de ontwikkeling van de mogelijkheden om meerdere verschillende technieken te kunnen toepassen. Dat houdt in dat er voldoende rekencapaciteit, opslagruimte en juiste software beschikbaar zijn en dat er aandacht bestaat voor inzichten, die data kunnen bieden. Het is ook cruciaal om mensen met de juiste kennis en ervaring binnen te halen en ervoor te zorgen dat er voldoende diversiteit is in de vaardigheden van deze medewerkers. Ook is het van belang om vooraf te weten wat de doelen van de data-analyses zijn om op daarbij passende technieken en vaardigheden te kunnen focussen.

Relevantie voor mededingingsautoriteiten

Ook een mededingingsautoriteit kan uiteraard veel van data leren. Datagedreven onderzoek kan leiden tot verbetering van de handhaving door kennisontwikkeling, en data-analyse kan een krachtig bewijs zijn bij fusiebeoordelingen of bij misbruikzaken waarbij schade aangetoond dient te worden. Een ex-postevaluatie kan leiden tot geïnformeerde aanpassingen van beleid. Automatisering van de bewerking van gegevens bevordert efficiëntie en toenemende beschikbaarheid van gegevens biedt kansen voor datagedreven detectie van anti-competitief gedrag.

Beoordelen van fusies vereist inschatting van het effect van de concentratie op de bepaalde markt. Dat wordt typisch uitgevoerd door het verzamelen van informatie

over marktverhoudingen en een zoektocht naar het aantal alternatieven beschikbaar in de markt na een eventuele fusie. Gesprekken met marktspelers en enquêtes bieden daarbij waardevolle inzichten maar met toenemende beschikbaarheid van data over prijzen en volumes is het vaak ook mogelijk om de vraag naar de producten in de betreffende markt direct te analyseren. Met een statistisch model kan de mededingingsautoriteit onderbouwde conclusies trekken over de situatie in de markt en met simulaties een beeld krijgen over de effecten van de fusie. Zo heeft de Autoriteit Consument en Markt een statistische analyse gebruikt bij de beoordeling van de fusie tussen Staatsloterij en Lotto.² De analyse was gebruikt voor een kwantitatieve schatting van de substitutiepatronen tussen producten van fuserende partijen. Aan de hand van de resultaten van dit soort analyses kan dan worden vastgesteld of er mededingingsrisico's ontstaan na de fusie. Als bijvoorbeeld blijkt dat twee producten sterke substituten voor elkaar zijn en er geen alternatief bestaat, is een fusie van aanbieders van deze producten risicovol. De statistische analyse wordt uiteraard gebruikt in de context van kwalitatieve gegevens zodat een volledig plaatje over de situatie in de markt kan worden geschetst.

Mededingingsautoriteiten hebben steeds vaker te maken met verticale afspraken en misbruik van machtspositie waar de concurrentieverstorende effecten aangetoond dienen te worden. Om de anti-competitieve effecten in kaart te brengen en het mechanisme erachter te verklaren moet een schadehypothese worden geformuleerd. De schadehypothese, ofwel de schadetheorie, is een aanname die de mededingingsautoriteit maakt over hoe de gedraging de concurrentie beperkt. Data-analyse kan de schadehypothese onderbouwen en het bewijs versterken. Als de empirische resultaten in strijd met de schadetheorie zijn, dan kan de mededingingsautoriteit deze uitkomsten echter niet negeren maar moet zij juist onderzoeken wat er aan de hand is en ernaar streven om deze uitkomsten te begrijpen. Men kan ervan uitgaan dat kwetsbaarheden van de schadetheorie door de tegenpartij hoogstwaarschijnlijk worden gebruikt in haar verdediging, dus het negeren van strijdigheden in het bewijsmateriaal pakt dan uiteindelijk toch verkeerd uit. De autoriteit moet bereid zijn om te concluderen dat de schadehypothese in de praktijk niet opgaat als dat uit de analyse blijkt. Dat kan betekenen dat er verder gezocht moet worden naar ander bewijs, of dat uiteindelijk een zaak gestopt moet worden omdat de schadetheorie niet voldoende robuust blijkt te zijn.

Tot slot kan de mededingingsautoriteit data gebruiken om signalen over anti-competitief gedrag te genereren. Deze signalen kunnen geïdentificeerd worden aan de hand van verdachte patronen in data over markten zoals bijvoorbeeld prijsontwikkeling. Zo is de concurrentie-waakhond niet afhankelijk van meldingen van burgers of clementieverzoeken, maar kan proactief onderzoek doen.

2. www.acm.nl/nl/publicaties/publicatie/15051/Staatsloterij-en-De-Lotto-mogen-fuseren-concentratiebesluit.

Detectie van kartels

In de wetenschappelijke literatuur is een aantal methoden voor de opsporing van kartels gepubliceerd. Harrington (2006)³ biedt een overzicht van wetenschappelijke literatuur gefocust op het ontwikkelen van economische detectiemethoden voor kartelopsporing. Hij identificeert twee manieren van kartelopsporing, namelijk een structurele aanpak én een aanpak gebaseerd op gedrag van ondernemingen.

De structurele aanpak maakt gebruik van geaggregeerde gegevens over markten om indicatoren te creëren die de karakteristieken van de markt weergeven en die de kans op kartelvorming kunnen beïnvloeden, zoals concentratie of het aantal spelers in de markt. Typische voorbeelden zijn het aantal concurrenten, de homogeniteit van producten, eventuele toetredingsdrempels of de stabiliteit van de vraag. De Nederlandse Mededingingsautoriteit (NMa) en haar opvolger de Autoriteit Consument en Markt (ACM) zetten economische screening in en de ACM publiceert over de aanpak.⁴ Deze methode kan worden gebruikt om sectoren te identificeren die extra aandacht van de toezichthouder verdienen.

De gedragsmatige aanpak benut de theoretische en empirische inzichten over het gedrag van deelnemers aan kartels. Zo toont Harrington (2006) dat ondernemingen in (ontdekte) kartels vaak ander gedrag vertonen in de periode gedurende de samenspanning dan in de perioden vóór en ná de kartelafspraken. Dat maakt het mogelijk om de veranderingen in gedrag van ondernemingen op te sporen met statistische analyse en *machine learning*-algoritmes. Een andere mogelijkheid is een statistische vergelijking tussen markten en het identificeren van ondernemingen, die een soortgelijk patroon laten zien als bedrijven in een kartel.

Harrington (2006) identificeert een aantal gedragspatronen vertoond door kartels. Afspraken leiden typisch tot hogere prijzen, lagere variantie in prijzen en hogere correlatie tussen de prijzen van concurrenten. Kartels worden ook getypeerd door stabiele marktaandeelen gedurende de tijd. Abrantes-Metz et al. (2006)⁵ illustreren deze dynamiek aan de hand van een voorbeeld van een ontdekt kartel in de VS. De afspraken waren gemaakt over prijzen bij aanbestedingen voor het leveren van bevroren baars. Figuur 1 toont het verloop van de prijzen en kosten van de betrokken ondernemingen. De tijdperiode kan worden verdeeld in drie blokken. De eerste is de kartelperiode. Daarna komt een korte transitie na de opsporing van de afspraak. De laatste periode toont dan hoe de ondernemingen zonder afspraken acteren. Wij kunnen constateren dat de prijs stabiel is in de periode voor augustus 1988 en niet sterk reageert op de

3. J.E. Harrington, 'Behavioral screening and the detection of cartels', *European competition law annual* 2006, nr. 68.
4. L. Petit, 'Uitkomsten Economische Detectie: Het economisch detectie instrument toegepast op de Nederlandse economie in 2009', *NMa Working Paper* 2013.
5. R.M. Abrantes-Metz, L.M. Froeb, J. Geweke en C. T. Taylor. 'A variance screen for collusion', *International Journal of Industrial Organization* 2006, nr. 3, p. 467-486.

Figuur 1 Prijzen en kosten van ondernemingen betrokken bij een kartelafspraken ontdekt in de VS

Leeswijzer: Eerste blok is de kartelperiode, tweede blok is de transitie na opsporing kartel en laatste blok is gedrag ondernemingen zonder kartelafspraken.

Bron: *The Unraveling of a New England Fish Scam*, 1991. *The Boston Globe City Edition*, p. A.1. November 3

veranderingen in kosten. Dat veranderde snel toen het kartel uit elkaar viel. De prijzen gingen meteen omlaag en de hele periode na de samenspanning vertoont een hogere variantie en correlatie met kosten.

Abrantes-Metz en Bajari (2009)⁶ stellen een aantal voorwaarden voor een goede screening vast:

1. Het aantal *false positives* en *negatives* moet minimaal zijn. Dat betekent dat weinig kartels worden gemist en concurrerende ondernemingen zelden als kartels worden bestempeld.
2. De implementatie moet eenvoudig zijn.
3. Het moet kostbaar zijn voor ondernemingen om de collusie te vermommen.
4. De gebruikte hypothesen moeten empirisch onderbouwd zijn.

In de volgende paragraaf presenteren wij ons screening-algoritme om kartels te detecteren, dat aan bovenstaande voorwaarden voldoet.

De algoritmische waakhond

Detectie van kartels is juist een voorbeeld van een probleem waar *machine learning*-technieken een waardevolle bijdrage kunnen leveren. De kern van een screening is het genereren van signalen over verdachte gebeurtenissen of patronen van grote hoeveelheden gegevens. Daarvoor is causaliteit in eerste instantie niet nodig. Een signaal van de screening is ook zeker geen bewijs dat er daadwerkelijk iets aan de hand is. Wél bieden de resultaten een kans om ontdekte patronen verder te onderzoeken met een 'ouderwetse' statistische analyse. Zonder

machine learning-technieken is de kans heel groot dat de autoriteit deze verdachte patronen anders zou missen.

De auteurs hebben een algoritme ontwikkeld dat verdachte patronen in prijsdata opspoort en signaleert of er sprake zou kunnen zijn van concurrentiebeperkende samenspanning. Een hypothese over 'wat is verdacht' moet dus worden geformuleerd. Als hypothese gebruiken wij de bovenstaande bevindingen van de literatuur dat bij kartels de prijzen hoger zijn, er minder variantie is in prijzen en het prijsverloop bij meerdere concurrenten identiek is, daarbij uiteraard rekening houdend met overige relevante factoren zoals kostprijsontwikkelingen. Hoge transparantie van prijzen in sommige markten leidt er echter toe dat deze patronen niet opvallend uit de data komen. Omdat prijzen zichtbaar zijn voor alle concurrenten is een bepaalde mate van coördinatie eenvoudiger als ook de marktomstandigheden hetzelfde zijn voor al deze ondernemingen. Verschillen in de mate van correlatie en/of variantie in prijzen tussen verschillende prijszetters kunnen bovendien worden verklaard door verschillen in kenmerken van deze bedrijven of markten. Dat wil zeggen dat als er in markt A hogere prijzen en een lagere variantie zijn dan in markt B, dit vaak verklaard kan worden door de karakteristieken van de desbetreffende markten. Een grotere en stabielere vraag in markt A is al voldoende voor de verklaring van het prijspatroon. Dat is een nadeel van de statische analyses; zie Abrantes-Metz et al. (2006) of Heijnen et al. (2014).⁷ Vanwege de bovenstaande problemen focussen we op veranderingen in prijsstrategie over tijd. Dan wordt het probleem van niet-geobserveerde karakteristieken van markten namelijk opgelost, omdat deze over het algemeen constant blijven over tijd. Deze aanpak is ook

6. R. Abrantes-Metz en P. Bajari, 'Screen for conspiracies and their multiple applications', *Antitrust* 2009, nr. 66.

7. P. Heijnen, M.A. Haan en A.R. Soetevent, 'Screening for collusion: a spatial statistics approach', *Journal of Economic Geography* 2014, nr. 2, p. 417-448.

voorgesteld door Harrington (2006) en Abrentes-Metz et al. (2006). Voor zover wij weten is onze screening de eerste die gebaseerd is op gedragsveranderingen over tijd.

Onze hypothese is gebaseerd op de aanname dat de prijzen van ondernemingen in een kartel het volgende patroon laten zien:

- constante prijsverschillen tussen kartelgenoten:
 - Dat betekent dat de prijsaanpassingen voor alle kartelgenoten nagenoeg op het zelfde moment plaatsvinden, wat wijst op coördinatie. Hierdoor wordt ook de lage variantie van de prijzen aannemelijker;
- lagere prijzen voor en nadat het kartel actief is:
 - een klassieke kartelhypothese;
- substitueerbaarheid van producten verkocht door de kartelgenoten:
 - Een schadelijke kartelafpraak betreft ondernemingen die met elkaar kunnen concurreren en dus kunnen profiteren van de afspraak. Dat betekent dat hun producten alternatieven voor elkaar zijn. In de praktijk betekent dit dat de producten vergelijkbare kenmerken dienen te hebben. Relevante productkenmerken zijn bijvoorbeeld kwaliteit, functie of locatie van het verkooppunt.

Box 1 Toelichting op de algoritmische waakhond

Het algoritme zoekt naar patronen die consistent zijn met de bovenstaande hypothese. De methode kan worden beschreven in enkele stappen:

1. Voor elke tijdperiode en voor elke⁸ combinatie van ondernemingen wordt de mate van coördinatie berekend. Wij gebruiken standaarddeviatie van onderlinge prijsverschillen.
2. Een model voor identificatie van structurele veranderingen in de data wordt gebruikt om veranderingen in prijsstrategie wat betreft coördinatie in prijzen en prijsniveau te identificeren. Zo wordt voor de prijzen in de tijd per onderneming gezocht naar zowel veranderingen in niveaus als veranderingen in prijstrend. Bij coördinatie zoeken wij dan per koppel van ondernemingen naar veranderingen in standaarddeviatie van onderlinge prijsverschillen. Hoe dit er in de praktijk uitziet, wordt hieronder aan de hand van

concrete voorbeelden toegelicht. De methode is gebaseerd op het hiërarchische Bayesiaanse model van Barry & Hartigan (1993).⁹

3. Het model verdeelt elke datareeks in meerdere blokken op basis van de veranderingen in standaarddeviatie van prijsverschillen. De hele tijdperiode is dus gesplitst in blokken met een variërende mate van coördinatie.
4. Vervolgens wordt gecheckt of de verandering in coördinatie overeenkomt met een verandering in prijsstrategie van minstens een van de twee ondernemingen in het koppel. Tevens wordt gecheckt of de periode met een hogere mate van coördinatie ook hogere prijzen vertoont.
5. Elk koppel dat aan bovenstaande voorwaarden voldoet, wordt gemarkeerd;
6. Vervolgens wordt gecheckt of er groepen van drie of meer ondernemingen kunnen worden geïdentificeerd die aan de bovenstaande voorwaarden voldoen. Bij een groot aantal ondernemingen kan dit met een clusteranalyse worden gedaan die gebaseerd is op de nabijheid van concurrenten. Nabijheid kunnen wij meten bijvoorbeeld met kruiselingse prijselasticiteit, lange termijn-prijscorrelatie of geografische nabijheid. Wij kiezen voor minimaal drie ondernemingen omdat verandering in prijscoördinatie van een koppel volledig kan worden gedreven door unilaterale aanpassing van de strategie door een van de ondernemingen. Bovendien is volgggedrag gebruikelijk in transparante markten. Dat maakt de kartelhypothese minder aannemelijk en wij zorgen er dus voor dat alleen écht opvallende patronen als verdacht worden gemarkeerd. Deze stap voorkomt dat er te veel *false positives* worden gevonden.

De laatste stap kan worden overgeslagen als er sprake is van een scherp afgebakende markt met een beperkt aantal ondernemingen. Ook als de gescreende markt niet transparant is en ondernemingen elkaars prijzen kunnen observeren, is de eis van zichtbare gedragsaanpassingen door meerdere ondernemingen niet van belang, omdat volgggedrag dan niet mogelijk is en transitie naar of van een hoge mate van coördinatie tussen twee ondernemingen op zichzelf verdacht genoeg is.

Na het doorlopen van de bovenstaande detectiestappen volgt de analysefase. In deze fase wordt kwalitatief of kwantitatief onderzocht of er mogelijke onschuldige verklaringen zijn voor de verdachte patronen. Eventuele

8. Hier speelt voorlopige marktafbakening een rol als meerdere aan elkaar gerelateerde markten worden geanalyseerd. Met grote hoeveelheden data kan rekentijd worden bespaard als wij alleen focussen op combinaties van ondernemingen die elkaars meest directe ('nabije') concurrenten zijn.

9. D. Barry en J.A. Hartigan, 'A Bayesian analysis for change point problems', *Journal of the American Statistical Association* 1993, nr. 421, p. 309-319.

Figuur 2 Identificatie van verdachte ondernemingen (fictieve data)

kwantitatieve analyse dient in deze fase wel met nadruk rekening te houden met mogelijke causaliteit. Daarvoor worden de ‘ouderwetse’ statistische methoden gebruikt. Schatting van de invloed van eventuele veranderingen in de vraag of prijs van grondstoffen en de bijbehorende significantie op de prijzen zijn voorbeelden van statistische analyses. Deze schattingen kunnen dergelijke patronen statistisch verklaren. Aanvulling met kwalitatieve informatie over de context van de markt is hierbij cruciaal.

Wij gebruiken de standaarddeviatie van de prijsverschillen als mate van coördinatie. Dit geeft in principe de samenhang tussen de prijzen weer. Men kan hierbij ook denken aan correlatie. Correlatie heeft een waarde tussen -1 en 1 en in onze empirische toepassing varieert deze behoorlijk tussen de periodes. Dit maakt het ontdekken van breuken in de data lastiger en het betekent ook dat aan één technische aanname van het onderliggende statistische model niet wordt voldaan.¹⁰ Daarom wordt gekozen voor variantie in prijsverschillen. Dit laat praktisch zien hoe belangrijk het is om goed te weten wat de methode precies inhoudt en hoe en waarom het werkt. Een alternatieve weergave van dezelfde data leidt hier tot een behoorlijke verbetering in prestatie.¹¹

De methode bootst een visuele analyse na

Modellen voor breukidentificatie worden vaak gebruikt voor beeldherkenning en ook in ons geval kan de methode gezien worden als een visuele beoordeling van de data. Voor concrete gevallen kunnen wij de prijsontwikkelingen visueel bekijken en kunnen wij identificeren

waar opvallende veranderingen plaatsvinden. Dat wordt echter lastig als wij een groot aantal ondernemingen of markten willen screenen. In plaats van handmatig duizenden grafieken te maken en te bekijken, doet het algoritme het werk voor ons en signaleert waar we naar op zoek zijn.

Wij zijn op zoek naar momenten die lijken op transities tussen kartel- en niet-kartelperiodes. Zoals hierboven beschreven verwachten wij dat er in een kartelperiode hogere prijzen, meer coördinatie en minder variatie in prijzen zijn ten opzichte van een niet-kartelperiode. Wij illustreren de werking van het algoritme aan de hand van fictieve data. Figuur 2 laat de resultaten zien van een voorbeeld van fictieve gegevens. In het linkerpaneel laten wij alle tien de gescreende ondernemingen zien. In het rechterpaneel worden drie ondernemingen geselecteerd die een gelijktijdige transitie naar een kartelperiode vertonen. Het rode blok markeert de periode na een transitie naar meer coördinatie, die overeenkomt met een breuk in de prijstrend voor alle drie de ondernemingen.

Figuur 3 laat de resultaten zien van het breukidentificatiemodel voor de coördinatie tussen de drie ondernemingen onderling. De toppanelen in de figuur vertonen de waarden voor de mate van coördinatie. Lagere waarden betekenen meer coördinatie. De panelen beneden in de figuur laten de geschatte kans op een breuk per periode zien. Voor alle drie de koppels kunnen wij een toename¹² in coördinatie observeren na periode 70. De kans op een breuk is dan ook zeer waarschijnlijk. Tussen ondernemingen A en B en ondernemingen A en C kunnen nog twee breuken in perioden 35 en 45 worden geïdentificeerd.

Om vast te stellen welke van de breuken aan onze hypothese over transitie tussen een kartel- en niet-kartelperiode voldoen, moeten wij ook kijken naar veranderingen in prijzen. Figuur 4 laat de resultaten zien van deze analyse. Een breuk rond periode 70 komt hier ook naar voren. Figuur 4 laat zien dat op het moment wanneer de prijzen meer gecoördineerd worden, de prijzen ook stijgen. Gezamenlijk is dit consistent met een transitie naar

10. Het model neemt een constante variantie aan en laat alleen de gemiddelden van de verdeling variëren tussen blokken. Zie Barry en Hartigan (1993) voor details.

11. Zoals voor vele andere modellen bestaat ook voor onze toepassing een functie in het statistisch programma R. Het draaien van het model is dus heel makkelijk. Wel moeten de waarden voor enkele parameters vooraf worden bepaald waarvoor diepgaande kennis van het statistisch model nodig is.

12. Lagere standaarddeviatie van prijsverschillen betekent meer coördinatie.

Figuur 3 Getraceerde breuken in coördinatie tussen ondernemingen A, B en C (fictieve data)

Figuur 4 Getraceerde breuken in prijstrend voor ondernemingen AB en C (fictieve data)

een kartelperiode met hogere mate van coördinatie en hogere prijzen bij deze drie ondernemingen. Bij onderneming C vindt het model nog enige aanwijzing voor een verandering in de prijstrend na periode 60. Deze vinden wij echter niet terug in Figuur 3 en deze breuk wordt dus niet als verdacht gemarkeerd.

Bij onderneming A kunnen wij ook een prijsdaling rond periode 35 opmerken. Die komt overeen met de afname in coördinatie tussen ondernemingen A en B en ondernemingen A en C in Figuur 3. Men zou dus kunnen zeggen dat dit een einde van een kartel zou kunnen zijn wanneer A een prijsoorlog aangaat. Dat is niet uit te sluiten maar we hechten niet veel betekenis aan gedragsverandering van slechts één partij, omdat een kartelafspraken altijd meerdere ondernemingen bevat. Wij zouden dus verwachten dat als periode 35 een einde van een kartel is, alle betrokkene partijen hun gedrag aanpassen omdat de kartelprijzen niet meer duurzaam zijn. Coördinatie zelf is in de praktijk te verwachten in transparante markten. Afhankelijk van de markt kunnen zulke afwijkingen in de data in de praktijk frequent zijn. Denk bijvoorbeeld aan kortingsacties. Het markeren van alle deze veranderingen zou vermoedelijk te veel *false positives* opleveren. Onze aanpak vindt dus alleen de verandering in periode 70 opvallend, die duidelijk plaatsvindt bij meerdere ondernemingen. De methode is echter aan te passen aan de hand van de situatie. Bij aanbestedingen waar prijzen niet publiek zijn, is coördinatie zelf al meer opvallend, omdat het voor ondernemingen onmogelijk is om elkaars prijzen te observeren. Voor aanbestedingsmarkten kunnen wij dus minder strenge eisen stellen voor de screening en bijvoorbeeld elke verandering in coördinatie als opmerkelijk bestempelen.

Voor de analyses is het overigens noodzakelijk om voor de variabele kosten te corrigeren, bijvoorbeeld kosten voor belangrijke inputs. Zo kan de prijs voor bevroren baars bij het voorbeeld in Figuur 1 gecorrigeerd worden voor de prijs voor verse baars die een belangrijke kostenpost is en zo is de olieprijs van belang voor een aantal geraffineerde producten en heeft de prijs van kobalt invloed op de productie van batterijen. Als er tussen gescreende ondernemingen of markten weinig overeenkomstige inputkosten zijn, dan is het nodig om achteraf na te gaan of er verklaringen bestaan voor de ontdekte patronen.

Conclusie

Er wordt in de laatste jaren steeds meer aandacht gegeven aan data en data-analyse, en aan de wens dat overheidsinstellingen niet achterlopen bij het bedrijfsleven. Daarbij spreken mensen over gebruik van *machine learning* en big data. In dit artikel hebben wij geconstateerd dat data uiteraard enorme waarde kunnen leveren voor vrijwel alle organisaties, maar ook dat de kerntaken van overheidsinstellingen anders zijn dan die van bedrijven zodat het benodigde gereedschap verschilt. De nadruk moet dus worden gelegd op ontwikkeling van de mogelijkheden om meerdere verschillende technieken te kunnen toepassen. Daarbij is ook van belang dat de focus niet alleen op de moderne termen moet liggen maar veel breder zodat de analyses goed aansluiten bij de onderzoeksvragen.

Om de complexe keuzes tussen verschillende methoden bij verschillende onderzoeksvragen te navigeren is het

enorm waardevol om verbanden met de academische wereld te leggen. De wetenschappelijk literatuur biedt vele oplossingen en inspiratie. Academici kunnen met hun expertise direct een bijdrage leveren aan oplossingen van maatschappelijke problemen. Actief contact vanuit de overheidsinstellingen kan de samenwerking alleen efficiënter maken. Congressen en workshops bieden hiervoor een mooie kans.¹³

Dit geldt ook voor mededingingsautoriteiten. Naast economisch onderzoek naar causale verbanden en effecten van concrete gedragingen zijn er ook kansen om vraagstukken met een voorspellingsaspect op te pakken. Daar spelen juist de *machine learning*-technieken wel een belangrijke rol. Zoals bij alle voorspellingen is hier causaliteit niet vanzelfsprekend maar dit is in eerste instantie ook niet nodig. Een typische toepassing van *data science*-technieken draait om de detectie van opvallende patronen in de data. Zo kan een mededingingsautoriteit bijvoorbeeld de markten screenen voor kartelafspraken, waarbij een uitkomst van een screening dan niet direct een bevestiging is van het bestaan van een afspraak maar wél een aanleiding kan zijn voor verder onderzoek.

Wij hebben laten zien dat een algoritme gebaseerd op het nabootsen van een visuele analyse van prijsdata kan signaleren waar risico's op illegale samenspanning bestaan. De methode is flexibel qua inzet in verschillende markten en toepassingen van diverse aannames over het gedrag van kartels. Het kan dus in meerdere markten worden ingezet. Bovendien kunnen soortgelijke *tools* op maat worden gebouwd voor markten met specifieke kenmerken, die het formuleren van overtuigende kartelhypothesen mogelijk maken. Wij stellen dat er bijvoorbeeld belangrijke verschillen zijn tussen transparante en niet-transparante markten. Bij verschillende toepassingen moet dus zorgvuldig worden nagedacht over een zinvolle kartelhypothese. De hypothese bepaalt dan welke patronen de autoriteit met het algoritme in de data wil ontdekken.

Het ontwikkelen van proactieve datagedreven *tools* maakt de toezichthouders minder afhankelijk van klachten die de autoriteiten slechts beperkt kunnen beïnvloeden. Dit betekent dat anti-competitieve afspraken die anders onopgemerkt zouden blijven, nu mogelijk wél kunnen worden geïdentificeerd. Tot slot kan de autoriteit door gebruik te maken van proactieve detectie afschrikwekkende signalen afgeven aan markten waardoor de vorming en stabiliteit van kartels beperkt kan worden.

13. Een voorbeeld van actieve dialoog met de wetenschap is de steun van de ACM voor de recente workshop over lerende algoritmes in Rotterdam, zie www.erim.eur.nl/e-code-erasmus-centre-for-optimization-of-digital-experiments/2018-workshop-on-multi-armed-bandits/organisers-and-sponsors/.