



Prijsalgoritmes, machine learning en mededinging

Prijzen worden steeds meer bepaald met algoritmes. Dit heeft veel voordelen voor zowel bedrijven als consumenten, zoals lagere kosten en een efficiëntere marktwerking. Er kleven aan deze opkomst van digitale prijsvorming echter ook mededingingsrisico's.

IN HET KORT

- ▶ Prijsalgoritmes kunnen leiden tot uitbuiting van marktmacht of illegale kartelvorming.
- ▶ Ook zonder instructies kunnen zelflerende prijsalgoritmes stilzwijgend samenzweren.
- ▶ *Machine learning* en kunstmatige intelligentie bieden ook mogelijkheden voor toezicht.

In hun boek *Virtual competition: the promise and perils of the algorithm-driven economy* uit 2016 doen rechtsgeleerden Ariel Ezrachi en Maurice Stucke een sombere voorspelling: algoritmes en *machine learning* zullen het einde betekenen van fatsoenlijke mededinging. Toezichthouders zullen machteloos komen te staan tegenover een steeds stabielere digitale kartelvorming, mogelijk gemaakt door automatische prijsaanpassingen of zelfs vormgegeven door zelflerende algoritmes.

Deze voorspelling heeft bijgedragen aan een grootschalig debat over de rol van algoritmes in markten, dat op zijn beurt weer geleid heeft tot meerdere studies over het onder-

werp (OESO, 2017; CMA, 2018; Autoridade da Concorrência, 2019; Autorité de la concurrence en Bundeskartellamt, 2019). Ook de Europese Commissie zit niet stil. Zo heeft de Commissie in juni 2020 aangekondigd een nieuw mededingingsinstrument te willen ontwikkelen om gehele markten te kunnen onderzoeken op mededingingsproblemen (Europese Commissie, 2020). Hierbij wordt er expliciet verwezen naar “het risico van stilzwijgende collusie, waaronder markten met verhoogde transparantie als gevolg van algoritmisch gestuurde technologische oplossingen, die in alle sectoren steeds meer voorkomen.”

In deze bijdrage richten wij ons op de mededingingsrisico's die kleven aan de opkomst van prijsvorming op basis van algoritmes en machine learning. Maar wat zijn algoritmes en machine learning eigenlijk? Simpel gezegd zijn algoritmes niets anders dan geautomatiseerde digitale handelingen. Deze kunnen heel eenvoudig zijn (bijvoorbeeld een prijsalgoritme dat automatisch de prijs van een concurrent volgt), maar ook heel ingewikkeld (bijvoorbeeld een prijsalgoritme dat dynamisch inschat wat een goede prijs is op basis van historische en huidige data). Machine learning is de tak van kunstmatige intelligentie en informatica die zich richt op

TIMO KLEIN

Consultant bij Oxera Consulting LLP en Universitair docent aan de Universiteit Utrecht

ROB

VAN DER NOLL

Econoom bij de Autoriteit Consument & Markt (ACM)

JAN SVITÁK

Econoom bij de ACM en PhD student aan Tilburg University

algoritmes die uit zichzelf kunnen leren om een bepaald doel te bereiken.

Op vele manieren hebben algoritmes en machine learning een positieve invloed op marktwerking en maatschappij. Zo bieden ze bedrijven nieuwe middelen om te concurreren op basis van merites, bijvoorbeeld door kosten te drukken, betere service te verlenen, of volledig nieuwe en innovatieve producten en diensten aan te bieden. Alle voordelen daargelaten, richten wij ons in deze bijdrage voornamelijk op de risico's hiervan. We stellen de volgende vragen: Wat zijn de voornaamste mededingingsrisico's bij de opkomst van algoritmes en machine learning? Waar is ons theoretisch of empirisch begrip nog gebrekkig? En waar zitten er wellicht tekortkomingen in het huidige mededingingsinstrumentarium?

Wij richten ons hierbij in het bijzonder op drie specifieke risico's: (1) bedrijven met marktmacht kunnen beter consumentensurplus onttrekken; (2) het kan makkelijker worden om (expliciete) kartels te vormen en te monitoren; en (3) algoritmes kunnen op eigen houtje stilzwijgend samenzweren. Tot slot bespreken we hoe algoritmes en machine learning ook door toezichthouders proactief gebruikt kunnen worden.

RISICO 1: BEDRIJVEN MET MARKTMACHT KUNNEN BETER CONSUMENTENSURPLUS ONTTREKKEN

Door het gebruik van algoritmes kunnen ondernemingen meer gegevens verzamelen, en die beter analyseren om zo een prijs vast te stellen. In de eerste plaats wil dit zeggen dat een prijs meer gedifferentieerd kan worden vastgesteld (bijvoorbeeld wat betreft de tijd, de plaats en de persoonlijke gegevens van de consument). Dit kan leiden tot een meer fijnmazige, persoonlijke prijsdiscriminatie. Het welvaartseffect van persoonlijke prijsdiscriminatie kan gunstig of ongunstig zijn, en dit raakt daarnaast aan privacy- en eerlijkheidsdiscussies (Botta en Wiedemann, 2019). De UK Competition & Markets Authority (CMA, 2018) bespreekt tevens prijsdiscriminatie als een tweede risico, naast kartelvorming bij de opkomst van prijsalgoritmes. De CMA concludeert echter wel dat er beperkt bewijs is voor gepersonaliseerde prijsvorming door middel van prijsalgoritmes (zie ook OESO, 2018).

Ten tweede kunnen ondernemingen door het gebruik van algoritmes de vraagomgeving beter analyseren, en daardoor een prijs hanteren die meer winst (en minder consumentensurplus) oplevert, voor zowel uniforme als gedifferentieerde prijzen. In het veldexperiment van Dubé en Misra (2017) wordt de optimale prijs voor een monopolist berekend middels machine learning. De auteurs vinden een optimale uniforme prijs van 281 dollar voor een bedrijf dat in werkelijkheid een uniforme prijs van 99 dollar vroeg. Dezelfde studie berekent ook dat optimale gepersonaliseerde prijzen leiden tot een daling van één procent in het consumentensurplus, terwijl een meerderheid van de consumenten ervan profiteert. Zowel uniforme als gepersonaliseerde unilaterale prijsstrategieën kunnen dus door het gebruik van algoritmes gaan veranderen, met mogelijk een verlaging van het consumentensurplus als gevolg.

Wat kan de mededingingsautoriteit doen als een onderneming door het gebruik van een algoritme zijn prijs bijna verdrievoudigt, simpelweg omdat de winstmaximalisatie beter wordt uitgevoerd? Bij excessief hoge prijzen of bij prijsverhogingen op basis van specifieke, fijnmazige klantsegmenten zou het verbod op misbruik van economische machtspositie in beeld kunnen komen. Art. 102(a) en 102(c) VwEU (Verdrag betreffende de werking van de Europese Unie) verbieden bijvoorbeeld in principe het opdringen van oneerlijke prijzen of ongelijke condities voor gelijke transacties. De toepassing hiervan komt echter met de nodige uitdagingen voor het mededingingstoezicht (Botta en Wiedemann (2019) bespreken dit voornamelijk in relatie tot Art. 102(c) VwEU; zie ook OESO, 2018).

Tot slot kunnen markten met meer gedifferentieerde prijzen (in de tijd of anderszins) onoverzichtelijker worden, waardoor concurrentie afneemt. Door variatie in prijsstructuren kan de perceptie ontstaan dat de producten meer verschillen dan dat ze werkelijk doen ('schijndifferentiatie'). Een minder transparante markt, waarin prijzen voor een bepaald product variëren op meer dimensies, zou ook het toezicht op fusies en misbruik van economische machtspositie ingewikkelder kunnen maken, omdat in veel standaardanalyses 'de prijs' centraal staat (OESO, 2017).

RISICO 2: HET KAN MAKKELIJKER WORDEN OM KARTELS TE VORMEN

Het tweede risico is dat algoritmes het makkelijker maken om een kartel te implementeren. OESO (2017) noemt drie functies van algoritmes die het leven van de kartelist vergemakkelijken: het monitoren van andere karteldeelneemers, het stimuleren van parallel gedrag, en het versturen van signalen die op coördinatie zijn gericht. De vierde functie ('zelfleren') komt aan de orde bij Risico 3. De implicaties voor het mededingingsbeleid worden onder andere besproken in OESO (2017), zie ook Rodriguez Tamayo (2020).

Het is een open (empirische) vraag in hoeverre deze functies inderdaad voorkomen in algoritmes, en of ze bijdragen aan kartelvorming en kartelstabiliteit. Een eerste stap voor mededingingsautoriteiten is daarom het doorgronden van de algoritmes die in de praktijk gebruikt zouden kunnen worden, door instructies in de code aan te wijzen die anti-competitief zijn. Ook is er een rol voor marktstudies met bindende aanwijzingen of aanbevelingen – zoals bijvoorbeeld beoogd met het nieuwe mededingingsinstrument dat vanuit de Europese Commissie is voorgesteld (Europese Commissie, 2020). Tot slot kan het risico op kartels een grotere plek in het fusietoezicht krijgen.

Twee recente theoretische bijdragen laten echter ook zien hoe algoritmes kartelvorming onstabiel kunnen maken. Miklós-Thal en Tucker (2019) en O'Connor en Wilson (2019) nemen aan dat het gebruik van algoritmes het voorspellen van de vraag minder kostbaar zal maken. Dit heeft twee effecten: hogere kartelwinst wanneer kartelvorming lukt, maar ook een betere inschatting hoeveel en wanneer het loont om af te wijken van een kartel. In theorie kan het gebruik van algoritmes er via het laatste mechanisme voor zorgen dat collusie niet houdbaar is in een markt waar dat zonder algoritmes wel het geval was.

RISICO 3: ALGORITMES KUNNEN OP EIGEN HOUTJE STILZWIJGEND SAMENZWEREN

Het derde risico heeft te maken met het gebruik van *reinforcement learning*-algoritmes voor prijszetting. Reinforcement learning is het type machine learning waarin het algoritme

niet alleen leert op basis van bestaande data, maar ook van het vallen en opstaan door met de eigen oplossingen te experimenteren. Sviták en Van der Noll (2020) beschrijven drie mechanismen die kunstmatige intelligentie in staat stellen om zonder communicatie tussen concurrenten uit te komen op hoge prijzen: gecorreleerd experimenteren, modelmisspecificatie en zogenaamde vooruitziende strategieën.

Gecorreleerd experimenteren

De simpelste vorm van een zelflerend algoritme betreft een techniek die alleen met behulp van experimenteren (met verschillende prijzen) en observeren van de uitkomst (winst) leert om een probleem op te lossen. Deze algoritmes volgen dus een pure vallen-en-opstaan-aanpak. Hansen et al. (2020) en Sviták en Van der Noll (2020) laten zien dat een hele klasse van dit soort algoritmes in staat is om monopoliewinsten te behalen. De unieke eigenschappen van deze klasse van zogenaamde index-algoritmes (Gittins, 1979) is dat het prijzen onafhankelijk van concurrenten optimaliseert, en een bepaalde deterministische vorm van experimenteren heeft. Hansen et al. en Sviták en Van der Noll laten zien hoe deze eigenschappen kunnen leiden tot gecorreleerd experimenteren, waarbij concurrerende algoritmes doorgaans dezelfde prijzen zetten en daarmee leren om hogere prijzen dan normaal te hanteren.

Modelmisspecificatie

In plaats van door puur vallen-en-opstaan kunnen prijsalgoritmes ook proberen om door middel van prijsexperimenten een onderliggend vraagmodel te leren en dat vervolgens te verbeteren. Zoals Cooper et al. (2015) en Den Boer (2015) bespreken, schatten dit soort algoritmes vaak slechts winst als functie van de eigen prijs. Cooper et al. laten echter zien dat leren op basis van een vraagmodel dat concurrentie negeert, leidt tot een onderschatting van de eigen prijselasticiteit – en daarmee dus tot hogere prijzen. Klein (2020) en Sviták en Van der Noll (2020) bespreken hoe in de praktijk het meenemen van de prijzen van concurrenten vanuit praktisch oogpunt moeilijk of zelfs onmogelijk kan zijn, waardoor dit soort modelspecificaties ook in de praktijk een zorg kunnen worden.

Vooruitkijkende strategieën

Het laatste mechanisme is gebaseerd op een dynamische vorm van reinforcement learning dat niet alleen huidige winst probeert te maximaliseren, maar ook rekening houdt met de langetermijnevolgen. Een eenvoudig en fundamenteel type hiervan is *Q-learning* (Watkins, 1989; Sutton en Barto, 2018). Toegepast op prijsapplicaties observeert Q-learning elke keer als het een prijs zet hoe dit de situatie (bijvoorbeeld de prijs van concurrenten) beïnvloedt. Het schat dan, door middel van zogenaamd dynamische optimalisatie, de langetermijnwaarde van het zetten van een bepaalde prijs in een bepaalde situatie. Q-learning is hierdoor in staat om strategisch gedrag te leren, waarbij het rekening houdt met reacties van concurrenten. Deze vooruitkijkende aard maakt het mogelijk om structurele prijsverlagingen door concurrenten te voorzien en te voorkomen – een eigenschap die zelfs beloofd wordt door bestaande commerciële prijsalgoritmes die op hoofdlijnen vergelijkbaar zijn met Q-learning (Pricecast Fuel, 2020). Calvano et al. (2020) en Klein (2019) laten door middel van simulaties zien dat Q-learning-algoritmes inderdaad in staat zijn om op supra-competitieve prijzen uit te komen zonder communicatie of expliciete instructies.

Er zitten nog wel veel praktische problemen aan het implementeren van prijsalgoritmes op basis van Q-learning. Voor collusie door Q-learning is er met name voldoende experimentatie in prijzen nodig om de uitkomsten van verschillende prijsstrategieën te kunnen vergelijken. Het is daarbij onzeker in hoeverre bedrijven in de praktijk bereid zijn om te experimenteren met prijzen, maar er zijn aanwijzingen dat dit wel al gebeurt. Zo gebruikt een aanbieder van AI-software voor prijszetting experimenten voor continue winstoptimalisatie (Eversight, 2020). Witte Huis (2015) concludeert ook dat er in de Verenigde Staten experimenten met prijzen voorkomen.

Een ander vereiste voor succesvolle coördinatie door zelflerende algoritmes is complementariteit in de werking van de gebruikte technieken tussen concurrenten. De aangehaalde artikelen analyseren scenario's waarin alle spelers identieke algoritmes gebruiken. Het is echter aannemelijk dat de beschreven mechanismen ook werken wanneer de

algoritmes enigszins van elkaar verschillen. Daarnaast kan de benodigde overlap tevens ontstaan door middel van *white papers* (Derakshshan et al., 2016), optredens op conferenties, of het gebruik van gezamenlijke softwareleveranciers of consultants.

Mededingingsimplicaties

De bovengenoemde literatuur toont aan dat zelflerende algoritmes technisch in staat zijn om supracompetitieve prijzen te bereiken, maar gebeurt dit ook in de praktijk? Assad et al. (2020) brengen in de context van de Duitse benzine markt het eerste empirische bewijs dat prijsalgoritmes inderdaad leiden tot hogere prijzen. Assad et al. schatten in wanneer benzinstations gebruik gaan maken van geautomatiseerde prijsalgoritmes. Ze vinden dat prijzen hoger liggen voor benzinstations die deze al gebruiken, dat dit met name het geval is wanneer concurrerende stations dit ook doen, en dat de hogere prijzen geleidelijk ontstaan.

De onderliggende mechanismes blijven deels onduidelijk. Desalniettemin lijkt het ontstaan van stilzwijgende afstemming met behulp van zelflerende algoritmes geen sciencefiction te zijn, zoals bijvoorbeeld werd gesuggereerd door Kühn en Tadelis (2017) en Schrepel (2017). Het vormt een apart en relevant vraagstuk, waarbij er met name gekeken moet worden naar de mogelijke praktische beperkingen (Klein, 2020).

In het geval van een stilzwijgende algoritmische collusie is het huidige instrumentarium van mededingingsautoriteiten ontoereikend, omdat de wetgeving alleen afstemming tussen *mensen* onderling bestraft (Harrington, 2018). Dit is niet aan de orde bij de beschreven mechanismes. De mogelijke juridische problematiek rond autonome kartelvorming maakt het begrijpen van de mechanismes achter autonome algoritmische collusie zeer relevant, ondanks een beperkt empirisch bewijs. Voldoende kennis bij beleidsmakers en toezichhouders moet ervoor zorgen dat gevallen van algoritmische collusie herkend worden. Het verbieden van bepaalde technieken (wat ook wel *compliance by design* genoemd wordt) of het toetsen van algoritmes in een simulatie lijkt niet werkbaar, omdat de uitkomsten sterk afhanke-

lijk zijn van de strategieën van concurrenten. Een algoritme kan namelijk niet samenzweren zonder dat concurrenten een complementaire strategie volgen. De combinatie van strategieën bepaalt de uitkomst, en niet de gebruikte techniek. Zo vinden Assad et al. (2020) bijvoorbeeld dat, als slechts één benzinstation een prijsalgoritme gebruikt, dit niet voldoende is om prijsverhogingen van concurrenten uit te lokken.

Een bevoegdheid om remedies op te leggen, na het vaststellen van een mededingingsbeperking, zou een betere manier kunnen zijn – en kan ook bij gevallen van ‘gewone’ stilzwijgende collusie worden ingezet, zoals in het Verenigd Koninkrijk, IJsland en Mexico (OESO, 2017). De definitie van collusie door Harrington (2018) en de overige opgedane kennis over algoritmische collusie kan dan gebruikt worden om de verdenkingen te staven en remedies te formuleren, zodat de samenzweringsmechanismen die aanwezig zijn in de algoritmes uitgeschakeld worden.

KANSEN VOOR MEDEDINGINGSTOEZICHT

Er zijn echter ook kansen voor mededingingsautoriteiten om gebruik te maken van de ontwikkelingen op het vlak van machine learning. Wij zien drie concrete kansen: automatische tekstanalyse, detectie van kartels, en het gebruik van causale machine learning. Hiernaar wordt tevens kort verwezen door onder anderen Sviták en Brouwer (2018).

Ten eerste bestaan er technieken voor het verwerken van tekst die het mogelijk maken om tijdrovende handmatige handelingen te automatiseren (Nay, 2019). Dit betreft bijvoorbeeld het filteren van binnengekomen signalen, ingediend door burgers wat betreft hun verdenkingen van overtredingen van de mededingingswet of het zoeken naar relevante bewijsstukken in een enorme hoeveelheid tijdens bedrijfsbezoeken binnengehaalde gegevens. Deze technieken worden op die manier al gebruikt door onder andere de Britse mededingingsautoriteit (CMA, 2020). Dit vormt een besparing op de schaarse capaciteit, die ingezet kan worden om meer zaken op te pakken of om meer diepgaande onderzoeken uit te voeren.

Ten tweede kunnen machinelearning-technieken gebruikt worden om nieuwe methoden voor proactieve

detectie van kartels te ontwikkelen — dus in het verlengde van een traditionele aanpak van karteldetectie (Petit, 2012; Van der Noll en Visser, 2009; Harrington, 2006). Huber en Imhof (2019) en Wallimann et al. (2020) laten voor een aanbestedingsmarkt in Zwitserland zien dat een machinelearning-model dat is getraind op een dataset met een bewezen kartel, in staat is om met behulp van statistische indicatoren op het niveau van individuele aanbestedingen de vervalste aanbestedingen te vast te stellen. Pivrnec (2020) toont daarnaast aan dat een model getraind op één dataset ook *voorspelkracht* heeft in een andere dataset, en dus kan helpen om nieuwe kartels te detecteren. Wachs en Kertész (2019) analyseren met een netwerkanalyse de inschrijfpatronen van ondernemingen, om zo verdachte inschrijvers te ontdekken. OESO (2016) ziet datagestuurde detectie van kartelvorming in publieke aanbesteding als een belangrijk onderdeel van haar aanbevelingen omtrent *bid rigging*.

Ook buiten de context van aanbestedingen kunnen machinelearning-technieken worden ingezet voor karteldetectie. Sviták en Brouwer (2018) ontwikkelden een breukidentificatiemodel dat gebruikt kan worden om een begin en/of einde van een kartelperiode te detecteren. De toenemende beschikbaarheid van bruikbare gegevens maakt karteldetectie steeds kansrijker, en de ontwikkeling van empirische methoden (inclusief machine learning) is dus zeer relevant.

Ten derde worden machinelearning-technieken in toenemende mate gebruikt voor econometrische schattingen van causale effecten. Populaire empirische modellen die worden gebruikt in de economische wetenschap bevatten namelijk een element van voorspelling. Denk bijvoorbeeld aan het verklaren van een endogene variabele door middel van exogene instrumenten in instrumentele variabele-modellen (Belloni et al., 2012) of door het (impliciet) schatten van de *counterfactual* in (synthetische) *difference-in-differences*-modellen (Athey et al., 2018). De datagestuurde aard van machinelearning-technieken betekent dat dit gereedschap zich uitstekend leent voor voorspellingen. De toepassing van machine learning kan de empirische prestaties van traditionele econometrische methoden dus versterken. Mededingingsautoriteiten gebruiken econometrische analyses voor het inschatten

van de anti-competitieve effecten van gedragingen en concentraties, en ook voor marktstudies die de toezichthouder helpen om bepaalde markten en ontwikkelingen beter te begrijpen; zie bijvoorbeeld ACM en NZa (2018), Berden et al. (2019) en Haasbeek et al. (2019).

CONCLUSIE

Alle voordelen daargelaten, zitten er aan de opkomst van prijsalgoritmes reële mededingingsrisico's waarvan toezichthouders zich bewust moeten zijn. In veel gevallen is het bestaande mededingingsinstrumentarium in principe voldoende, hoewel extra waakzaamheid van belang is. Dit is bijvoorbeeld het geval als bedrijven een dominante marktpositie misbruiken door middel van prijsalgoritmes, of algoritmes gebruiken bij het implementeren van een expliciete kartelovereenkomst. In andere gevallen is het bestaande instrumentarium echter moeilijk inzetbaar, en dient het wellicht heroverwogen te worden. Dit is bijvoorbeeld het geval wanneer prijsalgoritmes in staat zijn om stilzwijgende kartelvorming te ondersteunen of zelfs te initiëren. Het is op dit moment nog erg onduidelijk hoe stilzwijgende kartelvorming in de praktijk

precies zou kunnen werken – maar de theoretische zorgen zijn wel reëel.

Wij concluderen dat een marktstudie-instrument, zoals bijvoorbeeld voorzien in recente voorstellen vanuit de Europese Commissie, ervoor zou kunnen zorgen dat mededingingsautoriteiten niet achter het net vissen als het gaat om mededingingsbeperkingen die niet verboden zijn door de huidige mededingingswet, zoals bijvoorbeeld het samenstellen via zelflerende algoritmes. Op basis van onze discussie zou een dergelijke studie zich moeten gaan richten op drie vragen: wat zijn de indicatoren van de verschillende anti-competitieve uitkomsten, welk bewijs is er nodig om dit aan te tonen (data, code, documentatie), en hoe kan dit bewijs verzameld worden?

Tot slot zien we ook kansen voor toezichthouders om algoritmes en machine learning proactief te gebruiken ter verbetering van het bestaande toezicht. Dit betreft zowel het automatiseren van tijdrovende handmatige handelingen, als het ontwikkelen van nieuwe methodes voor het proactief voorspellen van mogelijk kartelgedrag of het econometrisch schatten van causale effecten.

LITERATUUR

- ACM en NZa (2018) *Beter kiezen op de polismarkt*. ACM/NZa Rapport, juli.
- Assad, S., R. Clark, D. Ershov en L. Xu (2020) *Algorithmic pricing and competition: empirical evidence from the German retail gasoline market*. CESifo Working Paper, 8521.
- Athey, S., M. Bayati, N. Doudchenko et al. (2018) *Matrix completion methods for causal panel data models*. NBER Working Paper, 25132.
- Autoridade da Concorrência (2019) *Digital ecosystems, big data and algorithms*. Issues Paper, juli. Te vinden op www.concorrencia.pt.
- Autorité de la concurrence en Bundeskartellamt (2019) *Algorithms and competition*. Rapport, november. Te vinden op www.autoritedelaconcurrence.fr.
- Belloni, A., D. Chen, V. Chernozhukov en C. Hansen (2012) Sparse models and methods for optimal instruments with an application to eminent domain. *Econometrica*, 80(6), 2369–2429.
- Berden, C., R. Croes, R. Kemp et al. (2019) *Hospital competition in the Netherlands: an empirical investigation*. TILEC Discussion Paper, 2019-008. Te vinden op www.acm.nl.
- Boer, A.V. den (2015) Dynamic pricing and learning: historical origins, current research, and new directions. *Surveys in Operations Research and Management Science*, 20(1), 1–18.
- Botta, M. en K. Wiedemann (2019) To discriminate or not to discriminate? Personalised pricing in online markets as exploitative abuse of dominance. *European Journal of Law Economics*, 9 december. On line te vinden op link.springer.com.
- Calvano, E., G. Calzolari, V. Denicolò en S. Pastorello (2020) Artificial intelligence, algorithmic pricing, and collusion. *American Economic Review*, 110(10), 3267–3297.

- CMA (2018) *Pricing algorithms: economic working paper on the use of algorithms to facilitate collusion and personalised pricing*. Competition & Markets Authority, 8 oktober. Te vinden op assets.publishing.service.gov.uk.
- CMA (2020) *Predictive coding: how technology could help to streamline cases*. CMA Blog, 24 juli. Te vinden op competitionandmarkets.blog.gov.uk.
- Cooper, W.L., T. Homem-de-Mello en A.J. Kleywegt (2015) Learning and pricing with models that do not explicitly incorporate competition. *Operations Research*, 63(1), 86–103.
- Demazeau, Y. (2016) PriceCast Fuel: Agent Based Fuel Pricing. In: *International Conference on Practical Applications of Agents and Multi-Agent Systems* (pp. 247–250). Springer, Cham.
- Derakhshan, A., F. Hammer en Y. Demazeau (2016) Pricecast fuel: agent based fuel pricing. In: Y. Demazeau, T. Ito, J. Bajo en J. Escalona (red.), *Advances in practical applications of scalable multi-agent systems: the PAAMS collection*. Cham: Springer, p. 247–250.
- Dubé, J.-P. en S. Misra (2017) *Scalable price targeting*. NBER Working Paper, 23775.
- Europese Commissie (2020) *Antitrustbeleid: Commissie raadpleegt belanghebbenden over een mogelijk nieuw mededingingsinstrument*. Persbericht, 2 juni. Te vinden op ec.europa.eu.
- Eversight (2020) *Retail pricing: continuously optime pricing with AI-powered experimentation*. Informatie te vinden op eversightlabs.com.
- Ezrachi, A. en M.E. Stucke (2016) *Virtual competition: the promise and perils of the algorithm-driven economy*. Cambridge, MA: Harvard University Press.
- Gittins, J.C. (1979) Bandit processes and dynamic allocation indices. *Journal of the Royal Statistical Society: Series B (Methodological)*, 41(2), 148–177.
- Haasbeek, S., J. Sviták en J. Tichem (2019) *Price effects of non-brand bidding agreements in the Dutch hotel sector*. ACM Working Paper, 7 juni.
- Hansen, K., K. Misra en M. Pai (2020) *Algorithmic collusion: supra-competitive prices via independent algorithms*. CEPR Discussion Paper, DP14372.
- Harrington, J.E. (2006) Behavioral screening and the detection of cartels. In: C.-D. Ehlermann en I. Atanasu (red.), *European Competition Law Annual 2006*. Oxford, VK: Hart Publishing, p. 51–68.
- Harrington, J.E. (2018) Developing competition law for collusion by autonomous artificial agents. *Journal of Competition Law & Economics*, 14(3), 331–363.
- Huber, M. en D. Imhof (2019) Machine learning with screens for detecting bid-rigging cartels. *International Journal of Industrial Organization*, 65, 277–301.
- Klein, T. (2019) *Autonomous algorithmic collusion: Q-learning under sequential pricing*. Amsterdam Law School Research Paper, 2018-15.
- Klein, T. (2020) (Mis)understanding algorithmic collusion. *Antitrust Chronicle: Algorithms Revisited*, 13 juli. Te vinden op www.competitionpolicyinternational.com.
- Kühn, K. en S. Tadelis (2017) *Algorithmic collusion*. Presentatie bij CRESE 2017.
- Miklós-Thal, J. en C. Tucker (2019) Collusion by algorithm: does better demand prediction facilitate coordination between sellers? *Management Science*, 65(4), 1455–1947.
- Nay, J. (2018) *Natural language processing and machine learning for law and policy texts*. SSRN Discussion Paper, 3438276.
- Noll, R. van der, en M. Visser (2009) De NMA als economische detective. *Markt en Mededinging*, 12(5), 156–160.
- O'Connor, J. en N.E. Wilson (2019) *Reduced demand uncertainty and the sustainability of collusion: how AI could affect competition*. FTC Working Paper, 341.
- OESO (2016) *Fighting bid rigging in public procurement*. Informatie te vinden op www.oecd.org.
- OESO (2017) *Algorithms and collusion: competition policy in the digital age*. Publicatie te vinden op www.oecd.org.
- OESO (2018) *Personalised pricing in the digital era*. OECD Background Note, 28 november. Te vinden op [one.oecd.org](https://www.oecd.org).
- Petit, L. (2012) *The economic detection instrument of the Netherlands Competition Authority: the competition index*. NMA Working Paper, 6.
- Pivrec, J. (2020) *Detection of bid-rigging cartels using machine learning techniques*. Masterscriptie, Universiteit van Amsterdam.
- Pricecast Fuel (2020) *Retail fuel pricing: management and optimization*. Informatie te vinden op www.azisystems.com.
- Rodriguez Tamayo, A. (2020) *Algorithmic tacit collusion under the EU Competition Law Framework*. Masterscriptie, Universiteit Leiden.
- Schrepel, T. (2017) *Here's why algorithms are NOT (really) a thing*, 15 mei. Artikel te vinden op leconcurrentialiste.com.
- Sutton, R.S. en A.G. Barto (2018) *Reinforcement learning: an introduction*, 2e editie, Cambridge, MA: The MIT Press.
- Sviták, J. en E. Brouwer (2018) De algoritmische waakhond: datagedreven mededingingstoezicht. *Tijdschrift voor Toezicht*, 9(2-3), 57–64.
- Sviták, J. en R. van der Noll (2020) De mechanismes van algoritmische collusie. *Tijdschrift voor Toezicht*, 11(1), 14–27.
- Wachs, J. en J. Kertész (2019) A network approach to cartel detection in public auction markets. *Scientific Reports*, 9(1), 1–10.
- Wallimann, H., D. Imhof en M. Huber (2020) *A machine learning approach for flagging incomplete bid-rigging cartels*. Université de Fribourg working paper 513.
- Watkins, C.J.C.H. (1989) *Learning from Delayed Rewards*. PhD Dissertation, University of Cambridge.
- Witte Huis (2015) *Big data and differential pricing*. Te vinden op obamawhitehouse.archives.gov.