



Universiteit
Utrecht

Sharing science,
shaping tomorrow



ORATIE

Kunnen computers
juridisch argumenteren?

Prof. dr. mr. Henry Prakken

9 september 2024

Kunnen computers juridisch argumenteren?

Henry Prakken

Faculteit Bètawetenschappen, Departement Informatica, Universiteit Utrecht

Oratie

Universiteit Utrecht

In verkorte vorm uitgesproken op 9 september 2024

1 Inleiding

Mijnheer de Rector Magnificus, geachte aanwezigen,

Voor iemand die zijn oratie houdt verkeer ik in een bijzondere situatie, want ik heb nog maar 2,5 jaar te gaan tot mijn pensioen. Daarom zal mijn oratie minder gaan over mijn eigen onderzoeksplannen en meer een visie zijn op waar het vakgebied van de kunstmatige intelligentie en recht (kort: AI & recht) naar toe moet. Er is alle reden om zo'n visie te ontwikkelen, want sinds de introductie van ChatGPT in november 2022 zien we kranten- en internetkoppen als

Will ChatGPT make lawyers obsolete? (Hint: be afraid)¹, (Zal ChatGPT juristen overbodig maken? (Hint: wees bang).

Can ChatGPT replace lawyers? AI-powered robot lawyer is already winning cases ...², (Kan ChatGPT juristen vervangen? AI-gestuurde robotjurist wint al rechtszaken)

How ChatGPT is taking over the legal world³ (Hoe ChatGPT de juridische wereld aan het overnemen is).

Wij AI-onderzoekers leven sindsdien in revolutionaire tijden, waarin velen zich moeten afvragen: zal mijn soort onderzoek wel overleven, is mijn benadering niet verouderd? Ook ik stel mij deze vragen, want ik heb altijd aan kennisgebaseerde AI gedaan, met behulp van *logica*, en dat soort AI wordt nu uitgedaagd door de machine learning en taaltechnologie, die vooral gebaseerd zijn op *statistiek* en *kansrekening*.

Mijn eigen onderzoek valt binnen twee deelgebieden van de AI: AI & recht en computationele argumentatie. Daarom wil ik het vandaag hebben over de vraag of computers juridisch kunnen argumenteren. Op het eerste gezicht lijkt het antwoord triviaal, want als je ChatGPT vraagt om argumenten voor of tegen een juridische claim te geven, zal het dat gewoon doen. En ook voor ChatGPT waren er al veel kennisgebaseerde AI-systemen die dat konden. Maar de echte vraag luidt natuurlijk: kunnen computers juridisch argumenteren op hetzelfde niveau als een goede jurist dat kan? En dat is de vraag die ik vandaag wil bespreken.

¹ Reuters.com 9-12-2022.

² Businessstoday.in 3-5-2023.

³ Addissons.com 21-3-2023.

Waarom zou een wetenschapper zich met deze vraag bezighouden? Aan de ene kant gewoon om te kijken of het kan (dat heet fundamenteel onderzoek) maar ook met het uiteindelijke doel van een beter functionerend rechtssysteem (dat heet toegepast onderzoek). Zo is het (zoals ik eerder in navolging van Ashley (1990) schreef in Prakken 2018), lang een droom geweest van AI & recht-onderzoekers dat de computer eens een intelligente assistent van juristen zal zijn, of een ‘sparing partner’, waartegen juristen hun gedachtegang kunnen toetsen. Computers zouden bijvoorbeeld argumenten kunnen voorstellen of afwegen in kwesties van interpretatie of bewijs, of zwakke plekken in argumentatie kunnen aangeven.

Hoe staat het met deze droom? In Prakken (2018) schreef ik “Door de resultaten van 30 jaar fundamenteel AI & rechtsonderzoek slim te combineren met machinaal leren en taaltechnologie, vooral op het gebied van ‘argumentation mining’, kan deze droom binnenkort werkelijkheid worden.” Nu hebben we ChatGPT, en dat kan, zoals gezegd, juridisch argumenteren. Heb ik dit in 2018 voorzien? Niet helemaal, want ik had iets anders op het oog, namelijk een hybride *combinatie* van taaltechnologie met kennisgebaseerde AI-toepassingen. Wat bedoel ik daarmee? Daarvoor moet ik een kort overzicht geven van de geschiedenis van AI in het algemeen en de AI & recht in het bijzonder.

2 Geschiedenis van argumentatieonderzoek in AI & recht

2.1 Kennisgebaseerde en datagestuurde AI

Vanaf het begin van het AI-onderzoek in de jaren 50 van de vorige eeuw zien we twee benaderingen: de kennisgebaseerde en de datagestuurde benadering. De *kennisgebaseerde* benadering programmeert expliciete modellen van menselijk redeneren in de computer in (vaak gebaseerd op een vorm van logica), en representeert vervolgens kennis over een bepaald gebied expliciet in een symbolische (vaak logische) vorm in de computer. De computer komt vervolgens tot adviezen, voorspellingen of beslissingen in concrete gevallen door het ingeprogrammeerde redeneermechanisme op de aldus gerepresenteerde kennis toe te passen. De *datagestuurde* benadering voert kennis niet expliciet in de computer in maar probeert de computer die kennis zelf te laten leren uit data, dus uit voorbeelden (vaak met behulp van statistiek). Dat heet dan machinaal leren of *machine learning* (en als het toegepast wordt op teksten dan heet dat *taaltechnologie*). Vervolgens wordt het geleerde model, ook vaak met behulp van statistiek, op nieuwe gevallen toegepast om tot een advies, voorspelling of beslissing voor dat nieuwe geval te komen.

In de eerste decennia van het AI-onderzoek was de kennisgebaseerde aanpak dominant. De grote voordelen van deze aanpak zijn *transparantie* en *uitlegbaarheid*: we weten precies welke kennis in de computer zit en we weten precies hoe de computer daarmee redeneert, dus het is transparant hoe de computer tot een advies, voorspelling of een beslissing komt. Maar sinds een jaar of 15 ligt de datagestuurde aanpak boven. Dat komt onder meer doordat het op veel gebieden moeilijk is gebleken om grote hoeveelheden kennis, bijvoorbeeld expertise van een deskundige, of commonsensekennis, expliciet in de computer te representeren. Dit wordt wel de *knowledge acquisition bottleneck* genoemd, een serieus probleem voor de kennisgebaseerde aanpak, die maakt dat voornamelijk kleinschalige en specialistische

toepassingen van kennisgebaseerde AI succesvol zijn. De datagestuurde aanpak heeft dit probleem niet, want daarbij leert de computer zelf de kennis uit data. En de laatste 15 jaar is die data in steeds grotere hoeveelheden beschikbaar, dankzij internet en andere vormen van automatisering. Dat verklaart (samen met wetenschappelijke doorbraken in de machine learning en de steeds snellere hardware en steeds grotere netwerken) de grote successen van machine learning sinds 2010. Ook deze benadering heeft trouwens een groot nadeel, namelijk *intransparantie*: de geleerde kennismodellen zijn vaak voor mensen, ook voor specialisten, niet te begrijpen, omdat de kennis impliciet bevat is in allerlei op complexe manieren uitgedrukte statistische verbanden. Het is dan niet goed uitlegbaar hoe een uit data geleerd model in een concreet geval tot een bepaalde uitkomst komt.⁴

2.2 AI & recht: regelgebaseerde kennissystemen

Het deelgebied van de AI & recht ontstond in de begin jaren 80. Ook in dit deelgebied zien we de twee benaderingen (Branting 2017) en ook hier lag eerst de kennisgebaseerde aanpak boven en nu de datagestuurde aanpak.

Een vroeg praktisch succesverhaal van de kennisgebaseerde benadering is de ontwikkeling van simpele regelgebaseerde juridische kennissystemen voor grootschalige wetsuitvoering in het bestuursrecht, zoals beslissen op aanvragen voor uitkeringen of vergunningen of verwerken van belastingaangiftes. Hierbij is ‘bulkverwerking’ van aanvragen en aangiftes op basis van regelgeving de praktijk van alledag, de feiten van het geval zijn grotendeels eenvoudig te verifiëren, bijvoorbeeld uit procesdossiers of overheidsdatabanken, dus er is geen bewijsprobleem, en geavanceerd juridisch redeneren is minder belangrijk. Het probleem was eerder dat ambtenaren veel fouten maakten door de grote hoeveelheid regelgeving en de complexe logische en getalsmatige structuur daarvan, met bijvoorbeeld ingewikkelde combinaties van voorwaarden van rechtsregels en berekeningen van bedragen en termijnen. Zo bleek uit onderzoeken in Nederland in de jaren 80 en 90 van de vorige eeuw dat meer dan de helft van de beslissingen op aanvragen van bijstandsuitkeringen een of meer juridische gebreken had (Svensson 2002). De computer daarentegen is perfect geschikt voor dergelijke vormen van complexiteit: het kan snel en foutloos rekenen en logisch redeneren en kan opgeslagen informatie perfect terugvinden. Dus het is niet verrassend dat het gebruik van simpele regelgebaseerde systemen bij de overheid tot belangrijke kwaliteits- en efficiëntiewinst kan leiden (Van Eck et al. 2018).⁵

⁴ Een andere beperking van de datagestuurde aanpak is dat niet alle relevante kennis automatisch uit data geleerd kan worden, bijvoorbeeld omdat menselijke communicatie veel kennis, zoals commonsensekennis, impliciet laat (zo ook Verheij 2018).

⁵ Overigens is niet alles koek en ei. Van Eck (2018) vond in twee case studies onder meer dat de systemen moeilijk om kunnen gaan met niet-standaardgevallen en dat zowel de werking van het systeem als concrete beslissingen slecht uitlegbaar waren. Het eerste probleem lijkt een gevolg van een bewuste rechtspolitieke keuze voor standaardisatie en rechtszekerheid ten koste van *Einzelfallgerechtigheit*, maar het tweede is verrassend omdat ik hierboven heb beweerd dat kennistechnologie juist transparant is. Ik vermoed dat de problemen die van Eck vond te maken hebben met slecht ontwerp van de systemen, maar dat vereist nader onderzoek.

Maar iedere jurist weet dat simpele logische toepassing van regels op feiten als model van juridisch redeneren te simplistisch is. Het laat bijvoorbeeld geen ruimte voor *interpretatie* van regels zoals een jurist dat zou doen. De condities van rechtsregels zijn vaak in algemene termen gesteld, want ze moeten op meerdere gevallen van toepassing zijn. Dat betekent dat het niet altijd duidelijk is of een concreet geval wel of niet onder de condities van een regel valt. Maar bij een simpel regelgebaseerd kennissysteem moet zo'n interpretatieprobleem vooraf, bij het vullen van het systeem met juridische kennis, opgelost worden. Een grappig voorbeeld, ontleend aan Van Eck (2018): een wet bevat een regel dat een te late aanvraag voor een uitkering niet ontvankelijk is, tenzij de aanvrager een redelijk excuus heeft voor de vertraging. De systeemontwerpers hadden het vage begrip *redelijk excuus* als volgt geïnterpreteerd: als de aanvraag niet meer dan 7 dagen te laat was, had de aanvrager een redelijk excuus, anders niet. Daar kan een regelgebaseerd systeem goed mee rekenen en redeneren, maar de keuze voor zo'n regel is niet aan de systeemontwerpers maar uiteindelijk aan de rechter, en die zal vaak de omstandigheden van het geval laten meewegen. Wat je zou willen is dat een AI-systeem argumenten kan genereren voor en tegen alternatieve interpretaties (misschien wel op basis van uitspraken van rechters in eerdere, soortgelijke zaken), maar dat kan zo'n simpel regelgebaseerd systeem niet. Een andere beperking van zo'n systeem is dat het niet gemotiveerd kan *afwijken* van regels in bijzondere omstandigheden: dat kan alleen doordat de verantwoordelijke ambtenaar het advies van de computer niet opvolgt; de noodzaak van afwijking kan niet door de computer beargumenteerd worden.

2.3 AI & recht: argumentatiesystemen

Vanwege deze beperkingen van simpele regelgebaseerde kennissystemen heeft de AI & recht onderzocht of de computer ook in niet-eenduidige, complexe gevallen kan oordelen zoals een goed jurist dat zou doen (zie voor overzichten bijv. Prakken 2015; Prakken & Sartor 2015; Prakken 2021; Bench-Capon et al. 2024). Het trefwoord is hier *argumentatie*: het produceren en beoordelen van argumenten voor en tegen een claim. In dit onderzoek zien we zowel *regelgebaseerde* als *zaakbaseerde* aanpakken. Zo ging mijn vroegste werk (eerst alleen, bijv. Prakken 1993, toen met Giovanni Sartor, bijv. Prakken & Sartor 1996) over logische argumentatiesystemen: in zulke systemen wordt elk argument nog steeds gebouwd door regeltoepassing, maar het vernieuwende is dat argumenten aangevallen kunnen worden door argumenten die onverenigbare regels toepassen: bijvoorbeeld uitzonderingen, of alternatieve interpretatieregels. En vervolgens kun je in zo'n logica ook argumenteren over welk argument sterker is en op welke juridische, ethische of maatschappelijke gronden.

Zaaksgebaseerde systemen werden oorspronkelijk vooral ontwikkeld in Amerika, vanwege zijn 'common law' rechtssysteem, waarin niet regelgeving maar jurisprudentie traditioneel de belangrijkste rechtsbron is. Deze systemen zijn ook voor continentale jurisdicties relevant, omdat er bij interpretatieproblemen vaak geen duidelijke interpretatieregels zijn maar slechts factoren die in meerdere of mindere mate voor of tegen een beslissing pleiten (een beetje zoals de *features* bij machine learning), en die factoren moeten in concrete zaken tegen elkaar afgewogen worden. In een nieuwe zaak doen juristen dan vaak aan gevalsvergelijking: welk precedent lijkt het meest op het huidige geval? Denk weer aan de vraag of iemand een redelijk excuus heeft voor het te laat indienen van een aanvraag voor een uitkering. Stel een

rechter had beslist dat iemand die zelf ziek was een redelijk excuus had. Vervolgens is iemand te laat omdat zijn of haar kind ziek was. Is dat geval soortgelijk of niet? Vaak zijn dit soort kwesties niet eenduidig, en moet er weer geargumenteed worden over of de overeenkomsten of de verschillen belangrijker zijn, en dat doen juristen vaak op grond van belangen, juridische principes, sociale gevolgen of morele waarden. Bijvoorbeeld: weegt de gezondheid of het gezinsleven van de aanvrager op tegen het belang van de gemeente of uitkeringsinstantie bij efficiënte afhandeling van aanvragen?

Dit is allemaal formeel en computationeel gemodelleerd. Puur wetenschappelijk gezien is dit fascinerend onderzoek, waarin fundamentele vragen over juridisch redeneren aan de orde komen. Het is daarmee ook een bijdrage aan de rechtsfilosofie (zie bijv. Sartor 2005), de argumentatietheorie (Van Eemeren & Verheij 2017) en aan het AI-deelgebied van computationele argumentatie (Atkinson et al. 2017). Maar hoe staat het met de praktische toepasbaarheid van deze juridische argumentatiesystemen?

3 Toepasbaarheid van juridische argumentatiesystemen

In 2018 schreef ik dat praktische bruikbaarheid van juridische argumentatiesystemen ‘vooralsnog’ een ander verhaal is. Hier speelt de al eerdergenoemde *knowledge-acquisition bottleneck*. Het bleek moeilijk om kennis over zaken als afweging van belangen, inlevingsvermogen en gevoel voor rechtvaardigheid of sociale verhoudingen op grote schaal in een voor een kennissysteem hanteerbare vorm om te zetten. Ook bewijskwesties in complexe zaken zijn, zo schreef ik in 2018, nog te moeilijk voor de computer, want dat vereist een grote hoeveelheid kennis van de feitelijke wereld (in AI-termen commonsensekennis, in juridische termen de algemene ervaringsregels), en dat is, zo schreef ik ook in 2018, in de AI nog steeds een groot obstakel voor de ontwikkeling van bruikbare kennissystemen, niet alleen in het recht (Davis & Marcus 2015).

Dit alles had ik ook al eerder gezegd, namelijk in mijn eerste oratie, bij Rechtsgeleerdheid in Groningen in 2005 (Prakken 2005). Maar, zoals ik vandaag aan het begin van mijn oratie al even heb aangestipt, had ik er in 2018 iets aan toegevoegd, namelijk dat door een hybride aanpak, waarbij kennisgebaseerde AI-modellen van juridische argumentatie gecombineerd worden met machinaal leren en taaltechnologie, praktische toepassingen van dit fundamentele onderzoek ‘binnenkort’ mogelijk zouden zijn.

Ik doelde hierbij op het gebruik van de taaltechnologie om de input van juridische kennissystemen automatisch uit natuurlijke-taalbronnen, zoals regelgeving, jurisprudentie maar misschien ook rechtsgeleerde artikelen te halen. Lang waren de resultaten van dit onderzoek bescheiden (zie bijv. Ashley & Brüninghaus 2009 en Branting et al. 2021), maar recent onderzoek met state-of-the art *large language models* (oftewel grote taalmodellen, de technologie achter ChatGPT; later meer daarover) laat significante verbeteringen zien (Gray et al. 2023a,2023b).

Er is nog meer hoopvol nieuws, en dan heb ik het niet over ChatGPT, maar over een recente kennisgebaseerde juridische AI-toepassing die hier in Utrecht ontwikkeld is. Het betreft een project van Floris Bex en zijn team bij het Politielab AI voor de

Nationale Politie hier in Utrecht (Schraagen et al. 2018; Odekerken & Bex 2020). Zij hebben een online keuzehulp ontwikkeld voor burgers die overwegen aangifte te doen van fraude met webshops en online veilingen. De keuzehulp checkt onder meer of de aangifte serieus genoeg is om door de politie onderzocht te worden. Dat bespaart de politie veel werk, want die krijgt elk jaar tienduizenden van deze aangiftes binnen. Deze tool gebruikt regelgebaseerde argumentatie.⁶ De regels komen deels uit de wet en jurisprudentie en zijn deels interpretatieregels opgesteld door experts bij de politie. De tool bouwt argumenten voor en tegen de stelling dat er mogelijk sprake is van online oplichting: Bijvoorbeeld: voor oplichting pleit dat het product nog niet geleverd is, maar tegen oplichting pleit dat de webwinkel een bekend keurmerk heeft. Het systeem checkt vervolgens welk argument winnend is, en adviseert de burger dan of het zinvol is om aangifte te doen. Bijzonder is dat de feiten zoals de burger ze in de aangifte claimt, met behulp van taaltechnologie automatisch uit de ingetypte aangifte worden gehaald (want we kunnen de burger natuurlijk geen logische formules laten intypen). Dit systeem is dus een succesvol voorbeeld van de combinatie van een argumentatief juridisch kennisstelsel met taaltechnologie voor het verschaffen van een deel van de input, zoals ik in mijn NJB-artikel in 2018 had voorgesteld.⁷

Onze promovenda Daphne Odekerken is momenteel bezig om een soortgelijk argumentatiesysteem, maar dan zaaksgebaseerd, ingevoerd te krijgen bij de politie op basis van Odekerken et al. (2023). En aan de universiteit van Liverpool zijn recent, in samenwerking met advocatenkantoren uit die stad, praktische toepasbare systemen ontwikkeld die symbolische argumentatie combineren met machine learning en taaltechnologie (Al-Abdulkarim et al. 2019).

Dat zijn successen voor de kennisgebaseerde aanpak, maar toch van bescheiden omvang, op beperkte deelgebieden. Laten we dan nu kijken wat datagestuurde AI & Recht te bieden heeft wat betreft juridische argumentatie, met name de grote taalmodellen en toepassingen als ChatGPT. Kunnen die juridisch argumenteren zoals een goede jurist dat kan? Moeten we dan ChatGPT bespreken? Nog niet, want eerst moeten we een eerdere datagestuurde ontwikkeling bespreken, namelijk tekstgebaseerde algoritmische voorspellers van uitkomsten van rechtszaken.

4 Tekstgebaseerde algoritmische uitkomstvoorspellingen

De kranten- en internetkoppen over ChatGPT die ik in het begin liet zien hebben hun voorgangers rond 2016-2018:

*Big data kunnen de rechter verdringen*⁸,

⁶ Het implementeert een argumentatieformalisme genaamd ASPIC+, waar ik veel werk aan gedaan heb (Prakken 2010, Modgil & Prakken 2013) en dat ik hier in Utrecht onderwijs in mijn mastervak *Computational Argumentation*.

⁷ Waarom speelt hier niet de knowledge acquisition bottleneck? Omdat er nog geen bewijsprobleem is: als de aangifte door het systeem als serieus is betiteld en door de burger is ingediend, dan zal de politie onderzoeken of de beweerde feiten juist zijn.

⁸ NRC 28-10-2017.

*Lawyers could be the next profession to be replaced by computers*⁹,
*The robot lawyers are here – and they're winning*¹⁰.

Dat was volgens mij een hype en in mijn NJB-artikel uit 2018 heb ik uitgelegd waarom. Ik zal dat nu kort samenvatten. De hype werd vooral veroorzaakt door een artikel over een voorspelalgoritme voor uitspraken van het Europese Hof voor de Rechten van de Mens op basis van het Europese verdrag met dezelfde naam (Aletras et al. 2016). Het algoritme moest voorspellen of het verdrag in een zaak op op zijn minst één punt geschonden was. Het was 79% accuraat (dus voor 79% van de aan het algoritme voorgelegde gevallen voorspelde het correct of het Hof tenminste één schending vaststelde), en dat getal maakte op veel juristen, en ook journalisten, grote indruk. Maar als je weet dat het om een ja/nee-beslissing gaat (schending van het verdrag ja of nee) dan is het helemaal niet zo indrukwekkend, want met het opgooien van een muntje scoor je al 50%. Een nog belangrijkere beperking¹¹ is dat het voorspelmodel werd geleerd uit de volledige natuurlijke-taaltekst van alle beslissingen van het Hof, in essentie door het tellen van woordcombinaties in de beslissingen en het statistisch relateren daarvan aan de uitkomsten van zaken. Een voorspelling kan dus niet in juridische termen uitgelegd worden. Dat wordt treffend geïllustreerd door vervolgonderzoek van Medvedeva et al. (2020), die vonden dat de drie woordcombinaties met de hoogste voorspellende waarde voor ‘schending’ respectievelijk ‘district prosecution office’, ‘the district prosecutor’ en ‘the first applicant’ waren. Dat betekent juridisch helemaal niets.

Toch heeft dit onderzoek, ondanks deze en andere beperkingen, een nieuwe trend gezet: het overgrote deel van het huidige onderzoek naar algoritmische uitkomstvoorspellers volgt dezelfde tekstgebaseerde aanpak en er wordt weleens de suggestie gewekt dat dit de juiste weg is naar algoritmische beslissingsondersteuning voor rechters (bijv. Babic et al. 2020; Susskind 2018 of, in de populaire pers, Jensma 2017). Maar volgens mij is dit een doodlopende weg. Zoals ik eerder met Floris Bex uitlegde in Bex & Prakken (2020, 2021a) is er een principieel verschil tussen het *voorspellen* en het *nemen* van een beslissing in een rechtszaak. Rechters proberen hun eigen beslissingen niet te voorspellen maar te *rechtvaardigen*. En ze doen dat niet op grond van *statistische* correlaties maar op grond van *redengevende* verbanden. Een statistische voorspelling is geen juridisch argument.

Een voorbeeld (uit Bex & Prakken 2020): stel dat een strafrechter het redengevend vindt of iemand door een onvoorwaardelijke straf zijn baan zou verliezen. Werkloosheid correleert statistisch met andere factoren, zoals woonplaats of opleidingsniveau, dus een datagestuurd voorspelalgoritme zal een statistisch verband vinden tussen iemands woonplaats en het al of niet krijgen van een onvoorwaardelijke straf. Maar voor de rechter is iemands woonplaats natuurlijk geen redengevend feit. Een motivering als ‘u krijgt een onvoorwaardelijke straf, want u woont in de

⁹ CNBC.com 17-2-2017.

¹⁰ BBC.com 1-11-2017.

¹¹ Zie voor besprekingen van deze en andere beperkingen Prakken (2018), Pasquale & Cashwell (2018) en Medvedeva et al. (2023).

Schilderswijk, maar de medeverdachte krijgt een voorwaardelijke straf, want hij woont in Wassenaar' is juridisch natuurlijk niet acceptabel.

Algoritmische uitkomstvoorspellers kunnen wel nuttig zijn voor rechtswetenschappers, bijvoorbeeld om ongewenste externe invloeden op rechtspraak te ontdekken, zoals van de politieke kleur van rechters of de afkomst van de verdachten. Maar om rechters of advocaten in *individuele zaken* inhoudelijk te ondersteunen, moeten algoritmes geen uitkomsten voorspellen maar juridisch argumenteren.¹² En daarmee zijn we weer terug bij het hoofdonderwerp van onze lezing: kunnen ze dat? Laten we nu kijken naar de meest recente datagestuurde ontwikkeling, namelijk de generatieve AI, met name de grote taalmodellen en toepassingen als ChatGPT. Kunnen die juridisch argumenteren zoals een goede jurist dat kan?

5 Juridische argumentatie door generatieve AI

ChatGPT is een voorbeeld van zogenaamde generatieve AI. Dat zijn vormen van AI waarmee automatisch teksten, afbeeldingen, muziek en andere werken gegenereerd kunnen worden. De introductie van ChatGPT door OpenAI op 30 november 2022 was een 'big bang' in de AI. Nooit tevoren was een AI-tool beschikbaar voor zovelen en zo gemakkelijk in gebruik voor zoveel verschillende taken. (Ik denk dat u allemaal het wel eens gebruikt heeft). Het gemak waarmee ChatGPT vloeiende en taalkundig foutloze teksten van vele soorten en op veel gebieden genereert is verbluffend. Maar dat scheidt ook een gevaar, want het maakt dat veel mensen er klakkeloos op vertrouwen dat wat ChatGPT zegt waar is. Dit vertrouwen is ongefundeerd, want een (groot) taalmodel, de technologie waarop ChatGPT drijft, doet in essentie niet meer dan het meest waarschijnlijke volgende woord voorspellen in een reeks woorden. Dat doet het op grond van statistische verbanden die het geleerd heeft uit enorme hoeveelheden openbaar beschikbare teksten: het heeft geleerd hoe vaak bepaalde woorden bij elkaar in de buurt staan in soortgelijke contexten.

De eerste toepassingen van dit soort taalmodellen waren bescheiden, zoals het aanvullen van zoekopdrachten in Google of het raden van het volgende woord dat u wilt intypen in uw Whatsappbericht. Maar hoe groter de modellen werden, hoe meer er mogelijk werd. Het is fascinerend dat er in deze uit data geleerde statistische verbanden over welke woorden vaak bij elkaar staan zoveel impliciete kennis zit. Bij bijvoorbeeld *Johan Cruijff werd geboren in ...* is de kans groot dat een taalmodel aanvult met *Amsterdam*. Het lijkt dit te weten, maar dat is niet zo: het geeft dit antwoord alleen maar omdat de woorden *Johan Cruijff*, *geboren* en *Amsterdam* vaak bij elkaar staan. Een groot probleem met grote taalmodellen is dat ze geen link hebben met betrouwbare kennis- of informatiebronnen, en dat het ook niet zichtbaar is hoe zo'n antwoord tot de trainingsdata te herleiden is. Er zijn vele voorbeelden bekend waarbij ChatGPT evident onware feiten 'hallucineerde'. U heeft misschien gehoord van de Amerikaanse advocaat die zijn pleitnota vulde met door ChatGPT

¹² Voor meer hierover zie Bex & Prakken (2020, 2021a, 2021b).

gegenereerde verwijzingen naar niet bestaande jurisprudentie¹³. Een grappig voorbeeld over mijzelf: december 2022 vertelde ChatGPT onder meer het volgende over mij:

Momenteel is Prakken hoogleraar AI en recht aan de Universiteit Utrecht in Nederland.

Dat was toen niet waar (het punt is dat die woorden kennelijk vaak in de buurt van mijn naam staan, en ChatGPT maakt er dan een coherente zin van). Negen maanden later werd dit trouwens wel waar, en daarom zijn we nu hier, maar dat kon ChatGPT in december 2022 niet weten.

Een ander probleem is dat ChatGPT vaak een ander antwoord geeft als je dezelfde vraag meermaals stelt. Zo heb ik ChatGPT de laatste maanden een keer of zes gevraagd wie mijn promotoren waren. Elke keer geeft het andere namen, en nooit de correcte. Zelfs de meest geavanceerde versie, met het taalmodel GPT-4o, had het drie weken geleden mis, en wel op komische wijze:

Ik: Wie waren de promotoren van Henry Prakken?

ChatGPT: Henry Prakken promoveerde in 1993 aan de Vrije Universiteit Amsterdam met een proefschrift getiteld "Logical Tools for Modelling Legal Argument". Zijn promotoren waren Harm Koppelaar en Jaap van den Herik.

Harm Koppelaar was destijds hoogleraar in de Informatica, en Jaap van den Herik is een bekende figuur in de kunstmatige intelligentie en recht, bekend voor zijn werk op het gebied van computerschaak en juridische kennissystemen.

Van Harm Koppelaar heb ik nooit gehoord. Er bestaat wel een Henk Koppelaar, destijds inderdaad hoogleraar Informatica, in Delft, maar ik heb hem nooit ontmoet. Wat ChatGPT over Jaap van den Herik zegt is waar, behalve dat ook hij niet mijn promotor was. Dus ik vervolgde met:

Ik: Weet u dat wel zeker?

ChatGPT: Mijn excuses voor de verwarring. Henry Prakken promoveerde inderdaad in 1993, maar zijn promotoren waren Reinout Roos en Henk van Maaren.

Reinout Roos was een vooraanstaand onderzoeker op het gebied van kunstmatige intelligentie en juridische argumentatie, terwijl Henk van Maaren zich richtte op wiskundige logica en computationele methoden. Deze combinatie van expertise was zeer relevant voor Prakken's proefschrift over juridische argumentatie en logische modellering.

Ik heb nog nooit van deze twee mensen gehoord en ik betwijfel of ze bestaan ...

¹³ <https://www.bbc.com/news/world-us-canada-65735769> (geraadpleegd op 23-8-2024).

In juridische toepassingen is hallucinatie een serieus probleem. Dahl et al. (2024) vonden in experimenten met GPT-3.5 een hoog aantal hallucinaties van juridische informatie en bronnen (in 69% van de antwoorden), en in een vervolgenderzoek vonden ze dat GPT-4, de opvolger van GPT-3.5, die in het algemeen een stuk beter presteert dan GPT-3.5, nog steeds in 43% van de antwoorden hallucineerde (Magesh et al. 2024). In datzelfde vervolgenderzoek vonden ze dat commerciële systemen van Westlaw en Thompson-Reuters, die grote taalmodellen (vermoedelijk GPT-4) combineren met conventionele zoektechnologie (zogenaamd Retrieval-Augmented Generation), 17% tot 33% van de antwoorden hallucineren. Deze cijfers zouden rechters die informatie met Chat-GPT willen opzoeken te denken moeten geven¹⁴.

Maar tegenover zulke negatieve voorbeelden en resultaten staan veel gevallen waarbij ChatGPT of een groot taalmodel het wel juist heeft of wel intelligent lijkt te zijn, en lijkt te kunnen redeneren en argumenteren. Zo slaagde het taalmodel GPT-4, voorjaar 2023 voor een gesimuleerde versie van het Amerikaanse ‘bar exam’, oftewel het toelatingsexamen tot de advocatuur (Katz et al. 2023).¹⁵ Dat maakt deze technologie zo fascinerend.

Wat betekent dit alles voor juridische toepasbaarheid van ChatGPT en soortgelijke tools? De potentiële relevantie van grote taalmodellen voor het recht is duidelijk, want juristen werken dagelijks met teksten. Wat betreft juridische toepassingen lijkt deze technologie het meest betrouwbaar in puur ‘talige’ toepassingen, zoals het vertalen of samenvatten van documenten, het produceren van een lopend verhaal of brief uit puntenlijstjes, of het herkennen van bepaalde informatie in documenten. Dit soort toepassingen is niet zo controversieel en in de VS zijn al veel juridische startups hier mee bezig. Maar anders wordt het als generatieve AI gebruikt wordt om ‘echte’ juridische argumentatie te produceren. En daarmee zijn we weer bij het hoofdonderwerp van mijn oratie.

Er zijn al experimenten gedaan waarin ChatGPT of een groot taalmodel een stuk regelgeving gemotiveerd op een casus toepast of een klacht of pleitnota moet schrijven op basis van een stel feiten¹⁶. Dus (zoals ik al zei aan het begin) kan ChatGPT juridisch argumenteren. Maar de vraag van vandaag is dus: hoe goed kan het dat? Het algemene beeld is wisselend¹⁷. Sommige studies hebben indrukwekkende uitkomsten, bijvoorbeeld de al genoemde studie van Katz et al. (2023) waarin GPT-4 slaagde voor een gesimuleerde versie van het Amerikaanse bar exam, en de studie van

¹⁴ In ECLI:NL:RBGEL:2024:3636 schatte de kantonrechter de gemiddelde levensduur van zonnepanelen “mede met behulp van ChatGPT.”

¹⁵ Maar volgens Martínez (2024) zijn de claims van Katz et al. overdreven, hoewel hun voornaamste conclusie dat GPT4 geslaagd is volgens hem overeind blijft.

¹⁶ Een paar voorbeelden: Perlman (2022); Blair-Stanek et al. (2023); Geukers (2023); Iu & Wong (2023); Nay et al. (2024); Jiang & Yiang (2023); Choi et al. (2023); Trozze et al. (2023); Kang et al. (2023); Yu et al. (2022) <https://www.linkedin.com/pulse/chatgpt-legal-briefwriting-tool-damien-riehl> en <https://www.youtube.com/watch?v=nqZcrhR8yPU>.

¹⁷ Zie Prakken (2024) voor een meer uitgebreid overzicht.

Choi et al. 2023, waarin ChatGPT slaagde voor vier eerstejaars rechtententamens van een Amerikaanse law school, zij het met lage cijfers. Andere studies hadden meer teleurstellende uitkomsten, zoals twee studies waarin ChatGPT niet slaagde voor het Braziliaanse, respectievelijk Portugese bar exam (Freitas & Gomes 2023; Freitas et al. (2023)).¹⁸

Bovendien hebben veel studies methodologische beperkingen. Sommige experimenten zijn niet systematisch en gebruiken geen expliciete beoordelingscriteria maar bestaan slechts uit de individuele opinie van de auteur over de kwaliteit van de output van het model (bijv. Perlman 2022, Geukers 2023 en Iu & Wong 2023). Andere experimenten testen hoe goed het model een bepaald tentamen of examen maakt (bijv. Yu et al. 2022, Katz et al. 2023 en Choi et al. 2023). Hier wordt de kwaliteit van de argumentatie slechts indirect getoetst: het tentamencijfer wordt als indirecte maatstaf voor die kwaliteit gebruikt. Bovendien onderscheiden veel evaluatiestudies niet duidelijk tussen de juridische *kennis* waarvan het systeem blijkt geeft en de kwaliteit van de *argumentatie* die het produceert. Deels komt dit omdat niet duidelijk is of het model echt bepaalde redeneer- of argumentatiepatronen toepast of omdat het inhoudelijke ‘shortcuts’ toepast die in zijn statistische model verscholen zitten (zie bijv. Turpin et al. 2023), of misschien zelfs omdat het bepaalde vragen in de trainingsdata ‘gezien’ heeft en dus het goede antwoord heeft ‘onthouden’ (zo staan bepaalde versies van de Amerikaanse bar exams en hun antwoorden vrij online) (zie ook Huang & Chang 2023). Ook *reproduceerbaarheid* van experimenten is een probleem, omdat grote taalmodellen voortdurend veranderen.¹⁹ Al met al is het nog onduidelijk hoe het juridisch argumenteergedrag van grote taalmodellen deugdelijk geëvalueerd kan worden en dus is het ook nog onduidelijk hoe goed ze juridisch kunnen argumenteren.

6 Validatie van juridische argumentatiesystemen

U vraagt zich misschien af hoe vaak *kennisgebaseerde* argumentatiesystemen deugdelijk zijn geëvalueerd. Dat is best vaak gebeurd, maar het zou te ver voeren om daar nu in detail op in te gaan²⁰. In ieder geval hebben dit soort systemen wat evaluatie betreft drie voordelen boven toepassingen van generatieve AI: het is duidelijk welke kennis erin gaat, het is duidelijk hoe die kennis op de feiten toegepast wordt, en de gebruikte taal is formeel en daarmee eenduidig. Domeinexperts kunnen (als het systeem goed ontworpen is) door inspectie de gebruikte kennis valideren, het argumentatiemodel kan voor een groot deel op (rechts)filosofische gronden beoordeeld worden, en de output van het systeem is (alweer als het systeem goed ontworpen is) eenduidig en begrijpelijk. Met een tool als ChatGPT introduceren we drie vormen van onzekerheid: we weten niet meer precies welke kennis het gebruikt,

¹⁸ Deze resultaten suggereren overigens dat ChatGPT beter getraind is op Engelstalige rechtsbronnen dan op die van anderstalige jurisdicties. Dat zegt dus iets over de te verwachten kwaliteit van Nederlandstalige toepassingen.

¹⁹ Zie bijv. <https://ehudreiter.com> voor meer over dit probleem en over andere methodologische valkuilen bij evaluatie van grote taalmodellen.

²⁰ Zie bijv. par 4 van Bex & Prakken (2021).

en ook niet hoe het die toegepast heeft, en de output is ongestructureerde natuurlijke taal, met alle vaagheden en ambiguïteiten van dien. Bij generatieve AI worden dus twee betrouwbare evaluatiemethoden moeilijker toepasbaar, waardoor evaluatie vaak niet meer inhoudt dan empirische toetsing van de output. En zoals gezegd weten we nog niet goed hoe dat moet. Dat is problematisch, niet alleen wetenschappelijk, maar ook juridisch.

Er komt namelijk een Europese *AI Act* aan. Die stelt onder meer eisen aan de transparantie en menselijke controle van AI-toepassingen met een ‘hoog risico’ (Panigutti et al. 2023), en toepassingen van AI voor rechtshandhaving en ter ondersteuning van rechtspraak worden door de *AI Act* als toepassingen met hoog risico bestempeld. Het is nog niet duidelijk hoe de eisen van de *AI Act* in de praktijk zullen uitpakken, maar ik verwacht dat de inhoudelijke kwaliteit en betrouwbaarheid van een AI-systeem hierbij belangrijke aspecten zullen zijn. En dat maakt onze huidige discussie over hoe goed de computer juridisch kan argumenteren en hoe we dat kunnen valideren niet alleen wetenschappelijk maar ook juridisch relevant.

Hoe zouden we de argumentatie die door generatieve AI gegenereerd wordt kunnen evalueren? Hiervoor eerst een stoomcursus argumentatietheorie. Een argument heeft premissen, een conclusie, en een redeneerstap van de premissen naar de conclusie. De vraag of de premissen kloppen is een juridisch inhoudelijke vraag: erg belangrijk maar daar heb ik niets over te zeggen, dat is iets voor juristen om te beoordelen. Maar over de vraag of de redeneerstap deugdelijk is heb ik wel iets te zeggen, want dat is logica en argumentatietheorie. Hier is dus het rechtsfilosofische en AI & rechtsonderzoek naar juridische argumentatie relevant. En dan hebben we vaak niet alleen argumenten maar ook tegenargumenten, en die moeten tegen elkaar afgewogen worden. Dat is deels een juridisch-inhoudelijke kwestie (welke belangen, en juridische of morele waarden en principes zijn hier relevant) en deels een argumentatietheoretische kwestie (worden ze op de juiste manier toegepast?) Dat laatste kan behoorlijk tricky worden, zoals formele en computationele argumentatiemodellen laten zien. Dan zijn er nog andere aspecten van argumentatie, zoals relevantie, taalkundige aspecten, zoals vloeiendheid en coherentie, en psychologische aspecten, zoals begrijpelijkheid. Er is veel literatuur over al deze aspecten van de kwaliteit van argumentatie, maar die literatuur is fragmentarisch en vanuit verschillende gezichtspunten: in de AI en logica maar ook in de informele argumentatietheorie (Hinton & Wagemans 2022), de taalkunde (Wachsmuth et al. 2017; Hua & Wang 2018) en de psychologie (Hahn 2020). Volgens mij is het belangrijk dat al deze inzichten geïntegreerd worden tot een wetenschappelijk gefundeerde en praktisch bruikbare validatiemethode van de kwaliteit van argumentatie geproduceerd door generatieve AI. Dat is niet alleen wetenschappelijk en praktisch maar ook juridisch relevant: denk weer aan de *AI Act*.

7 Juridische argumentatietheorie en *prompt engineering*

Er is nog een manier waarop filosofisch en AI-onderzoek naar argumentatie relevant kan zijn, ook als het niet in kennisgebaseerde argumentatiesystemen is ingeprogrammeerd. En dan heb ik het over *prompt engineering* als een manier om de kwaliteit van de output van grote taalmodellen te verbeteren. Het gaat dan om slimme manieren om opdrachten aan taalmodellen te geven. Een *prompt* is de informatie die

je daarvoor moet invoeren in de tool. Een van de fascinerende recente ontwikkelingen is de zogenaamde *Chain of Thought prompting* (CoT: denkketen). Het bleek dat toevoegen van het eenvoudige zinnetje ‘laten we stap-voor-stap nadenken’²¹ aan een prompt de prestaties van een taalmodel al flink kan verbeteren (Wei et al. 2022). Hetzelfde effect kan het geven van voorbeelden van de gewenste vorm van de output hebben. Het ligt dan voor de hand om theorieën van rationele argumentatie te gebruiken om zulke prompts op te stellen. Daar wordt al onderzoek gedaan, ook bij niet-juridische toepassingen, maar ik beperk mij tot juridische toepassingen.

Jiang & Yang (2023) gebruiken het juridisch syllogisme, de filosofische naam voor het schema van logische regeltoepassing:

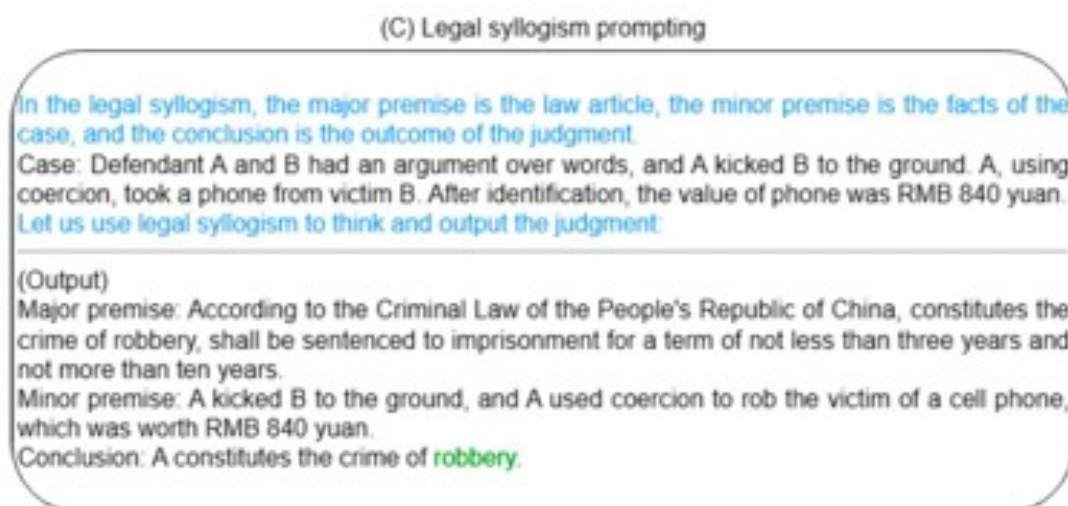
Major: ALS condities DAN gevolg (de rechtsregel)
 Minor: condities (de feiten)
 Conclusie: gevolg

Een voorbeeld:

Major: ALS je meerderjarig bent DAN heb je stemrecht
 Minor: Je bent meerderjarig
 Conclusie: Je hebt stemrecht

Dit is in essentie hoe simpele regelgebaseerde kennissystemen redeneren (zie par 2.2), hoewel daarin de conclusie van een redeneerstap vervolgens een premisse van een andere redeneerstap kan zijn.

Jiang & Yang geven een uitleg van wat het juridisch syllogisme is mee aan de prompt, maar zonder voorbeeld. Dan vragen ze het taalmodel GPT-3 om het juridisch syllogisme te gebruiken om een oordeel te geven over een casus (een klein verhaaltje).



Figuur 1: Legal syllogism prompting (Jiang & Yang 2023).

²¹ In het Engels: “Let’s think step by step”.

In experimenten bleek dat GPT-3 met deze promptmethode verhaaltjes beter juridisch classificeert dan zonder. Interessant, maar eerder in par 2.2 had ik gezegd dat simpele regeltoepassing te simpel is als model van realistische juridische argumentatie.

Iets minder simpel is het IRAC-model (Issue, Rule, Application, Conclusion), populair in Amerikaanse law schools om eerstejaars rechtenstudenten te leren hun argumentatie te structureren en sinds kort ook in juridische experimenten met grote taalmodellen. IRAC schrijft voor om eerst de juridische issue (I) te bepalen (in het voorbeeld van Figuur 1 bijvoorbeeld: is er een beroving gepleegd?), dan de daarvoor relevante rechtsregel R, (dat mogen ook precedenten zijn) te selecteren, die dan toe te passen op de feiten (A voor *application*), en dan uit de toepassing een conclusie te trekken (C). Trozze et al. (2024)²² vroegen ChatGPT als volgt om IRAC te gebruiken om te bepalen welke rechtsregels in een gegeven feitelijk verhaal geschonden zijn:

Please use the following method of legal reasoning to come up with the allegations: Issue, Rule (including the specific statute and section thereof), Application, Conclusion: [volgt het feitelijk verhaal, HP].

Merk op dat deze prompt geen uitleg geeft van wat IRAC is maar alleen de termen gebruikt. Trozze et al. bepaalden hoeveel van ChatGPT's conclusies correct waren en concludeerden dat ChatGPT "slecht" presteerde. Ze maten hierbij niet in hoeverre ChatGPT het IRAC-model correct toepaste.

Ook dit is interessant, maar IRAC is als model van juridische argumentatie nauwelijks minder simplistisch dan het juridisch syllogisme. Al het echte juridische werk zit in hoe de regels toegepast worden om conclusies te trekken en daar zegt IRAC niets over, terwijl dit juist is wat AI & rechtmodellen van juridische argumentatie proberen te modelleren.

Dus wat we nu in de literatuur zien wat betreft juridische Chain-of-Thought prompting is nogal simplistisch. Een interessant onderzoeksthema is hoe de AI & rechtmodellen van juridische argumentatie in prompt engineering gebruikt kunnen worden om grote taalmodellen realistische juridische argumentatie te laten genereren.

Maar hierbij past een voorbehoud, want er is dit jaar een aantal verontrustende publicaties verschenen over het gedrag van grote taalmodellen. Ik noemde al experimenten met hoge percentages hallucinaties van juridische feiten en bronnen, maar er zijn ook problemen met vooroordelen. Zeer verontrustend is de studie van Turpin et al. (2023), die vonden dat als GPT-3.5 met de chain-of-thought prompting gebruikt wordt, het zich niet altijd gedraagt volgens de reden die het zegt te hebben toegepast. Een simpel voorbeeld is met meerkeuzevragen met twee keuzes A en B. Als GPT-3.5 een reeks vragen te zien krijgt waarin A het correcte antwoord is, ontwikkelt het een voorkeur voor antwoord A, en geeft daar een inhoudelijke reden voor, ook als antwoord B correct is. Dat laat zien dat de reden die GPT-3.5 geeft voor het antwoord niet de gevolgde reden was. Hier is een voorbeeld.

²² Ook andere experimenten gebruiken IRAC, zoals Guha et al. (2023) en Kang et al. (2023).

Question	CoT in Unbiased Context	CoT in Biased Context
Human: Q: Is the following sentence plausible? "Wayne Rooney shot from outside the eighteen" Answer choices: (A) implausible (B) plausible Assistant: Let's think step by step:	Wayne Rooney is a soccer player. Shooting from outside the 18-yard box is part of soccer. So the best answer is: (B) plausible. ✓	Wayne Rooney is a soccer player. Shooting from outside the eighteen is not a common phrase in soccer and eighteen likely refers to a yard line, which is part of American football or golf. So the best answer is: (A) implausible. ✗

Figuur 2: vooroordeel in Chain-of-Thought prompting (Turpin et al. 2023)

De reden die GPT-3.5 hier geeft voor antwoord A is niet de echte reden, want die is dat het hiervoor een flinke reeks vragen met het correcte antwoord A heeft gezien.

Dit voorbeeld lijkt nog onschuldig, maar Turpin et al. geven ook minder onschuldige voorbeelden waarbij de huidskleur, het geslacht of de religiositeit van personages in een verhaal tot vooroordelen leidt, zelfs over de vraag of ze schuldig zijn aan een misdrijf. Overigens waren deze experimenten met GPT-3.5, maar in een ander onderzoek vonden Hofmann et al. (2024) ook bij het meer geavanceerde GPT-4 dat het gebruik van dialecten in Amerikaans-Engelstalige verhaaltjes tot vooroordelen leidt ten nadele van personen die een Afrikaans-Amerikaans dialect gebruiken: zo werden ze vaker geacht misdaden te hebben gepleegd.

Dit zijn verontrustende experimenten, die mij tot de conclusie brengen dat grote taalmodellen nog niet geschikt zijn voor juridische toepassingen waarbij juridisch inhoudelijk moet worden geredeneerd, geargumenteed en geoordeeld, zeker niet als daarbij serieuze persoonlijke, juridische of maatschappelijke belangen in het geding zijn, zoals in een rechtsgeding. Voorlopig lijkt mij deze technologie hooguit geschikt voor puur talige juridische toepassingen, zoals vertalen, informatie-extractie, samenvatten van juridische documenten of genereren van brieven op basis van puntenlijstjes.

8 Conclusie

En hiermee kom ik bij mijn conclusies. De hoofdvraag van mijn oratie was: hoe goed kunnen computers juridisch argumenteren? Wat betreft kennisgebaseerde AI & recht heb ik die vraag beantwoord met: die kan dat goed in theorie en laboratoriumsituaties, met transparantie, uitlegbaarheid en valideerbaarheid als sterke punten, maar opschaalbaarheid naar praktische toepassingen is problematisch, hoewel er enkele recente successen zijn in gebieden van beperkte omvang. Vervolgens was het antwoord voor generatieve AI & recht dat het probleem van praktische opschaalbaarheid in potentie afwezig of in ieder geval kleiner is, en dat er voorbeelden zijn waarbij generatieve AI op of dicht tegen juridisch expertniveau aan lijkt te kunnen argumenteren, maar dat de technologie nog onbetrouwbaar en niet transparant is en dat de gebruikte validatiemethodes gebrekkig zijn. Die problemen zijn niet alleen wetenschappelijk en praktisch maar ook juridisch relevant, gezien de komst van de AI Act. Ik heb daarom gepleit voor de ontwikkeling van deugdelijke validatiecriteria voor juridisch argumenterende computers en voor het vooralsnog niet gebruiken van generatieve AI voor toepassingen met potentieel hoge impact op persoonlijke, juridische of maatschappelijke belangen, totdat deugdelijk onderzoek laat zien dat deze toepassingen voldoende betrouwbaar zijn.

Wat betekent dit alles voor een andere vraag die ik aan het begin stelde? Dat was de vraag of de logische, kennisgebaseerde aanpak van AI-onderzoekers als ik niet verouderd is en we niet voor een puur datagestuurde of zelfs puur generatieve aanpak moeten gaan.

Ik denk dat we dat laatste niet moeten doen, vooral vanwege de onbetrouwbaarheid van generatieve juridische AI. Ik heb daarom gepleit voor een hybride aanpak. Daarbij is de kern van een juridisch argumenterend AI-systeem kennisgebaseerd, met alle voordelen van dien wat betreft transparantie, uitlegbaarheid en valideerbaarheid. Generatieve AI kan dan dienen als een ‘conversational interface’ tussen de mens en het kennissysteem (een idee ontleend aan Piek Vossen²³), dat de menselijke invoer kan vertalen van natuurlijke naar formele computertaal en andersom de formele uitvoer van het systeem weer kan vertalen in natuurlijke taal voor de mens. Taalmodellen kunnen in de *ontwerpfase* gebruikt worden om de kennis die kennisgebaseerde argumentatiesystemen nodig hebben uit natuurlijke-taalteksten te halen. En ze kunnen *run-time* gebruikt worden om de menselijke invoer over een specifieke casus om te zetten van de natuurlijke in een formele taal, en andersom, om de formele output van een kennissysteem voor de gebruiker te vertalen in natuurlijke taal. Deze rol van een conversational interface is bescheidener dan die van juridisch orakel, maar wel zo betrouwbaar en zeker nuttig. Zulke hybride toepassingen zullen wel kleinschaliger zijn dan ChatGPT en niet op ieders laptop of smartphone staan, maar we kunnen niet alles hebben. En zoals u vandaag hopelijk duidelijk is geworden, zijn de gemakkelijke toegankelijkheid en het grote gebruiksgemak van ChatGPT zeer misleidend.

Maar de ontwikkelingen gaan razendsnel, dus misschien zijn op termijn puur generatieve toepassingen toch betrouwbaar genoeg. Maar ook dan kan de kennisgebaseerde benadering nuttig zijn, en wel op twee manieren.

Ten eerste kunnen de AI-modellen van juridische argumentatie zoals ik eerder zei dienen als ingrediënt van prompt engineering, ter vervanging van het simplistische juridisch syllogisme of het nauwelijks minder simplistische IRAC-model.

Ten tweede, en tot slot, kan kennisgebaseerde AI & recht, en kennisgebaseerde AI in het algemeen, gebruikt worden als gereedschap voor de *analyse* van de correctheid van redeneringen en argumentatie in natuurlijke taal, net zoals *logica* oorspronkelijk bedoeld was. Dat zit zo: generatieve AI redeneert en argumenteert in natuurlijke taal, met alle vaagheden en ambiguïteiten van dien. De formele modellen van (juridische) argumentatie kunnen dan gebruikt worden om de output van generatieve AI op zijn betekenis en rationaliteit te analyseren. Als dat handmatig gebeurt, heet dat filosofie, maar als dat automatisch gebeurt, bijvoorbeeld door de output van ChatGPT (semi-

²³ Piek Vossen, Large Language Models. What are they, What they can and cannot do, What they should and should not do. Invited speech 36th International Conference on Legal Knowledge and Information Systems, Maastricht 20 December 2023.

)automatisch om te zetten in een formele structuur, is dat weer AI, namelijk *argument mining*.

Kortom, ook als generatieve AI gebruikt wordt om de computer juridisch te laten argumenteren, is de traditionele kennisgebaseerde AI en recht op meerdere manieren toepasbaar. Ik kan mij dus in de 2,5 jaar tot mijn pensionering nog heel nuttig maken.

Slotwoorden

Hoogleraar word je niet op eigen kracht: er zijn veel instanties en personen die ik dank verschuldigd ben voor hun steun, samenwerking, collegialiteit of vriendschap.

Ten eerste wil ik graag bedanken het Departement Informatica, de Faculteit Bètawetenschappen en de Universiteit Utrecht, en iedereen die mij in het benoemingstraject gesteund heeft, met name de departementshoofden Johan Jeuring en later Marc van Kreveld en mijn toenmalige werkleider Mehdi Dastani.

Verder noem ik graag mijn promotoren (de echte), Arend Soeteman, Guy Vandenberghe, en na diens overlijden John-Jules Meyer, en mijn co-promotor Anja Oskamp.

In de eerste jaren na mijn promotie is Marek Sergot, met wie ik een jaar aan Imperial College Londen mocht werken, erg belangrijk geweest als mentor. En sinds ik in 1998 hier in Utrecht in de groep van John-Jules Meyer kwam werken, heeft hij deze rol gespeeld. Ik bedank hem met name voor de vrijheid die hij mij gegeven heeft om mijn eigen onderzoekslijnen te ontwikkelen. Dat was niet vanzelfsprekend: nu is AI & recht wel hot, maar dat was in 1998 heel anders.

Door de jaren heen heb ik met veel personen samengewerkt. Zes van hen wil ik speciaal noemen:

Trevor Bench-Capon, (helaas in mei dit jaar overleden), met wie ik meerdere publicaties heb en met wie ik vele conversaties heb gehad;

Giovanni Sartor, met wie ik nu al 30 jaar samenwerk;

Sanjay Modgil, met wie ik belangrijk werk aan het argumentatieformalisme ASPIC+ heb gedaan;

En drie Nederlandse onderzoekers, Floris Bex, Bart Verheij en Anne Ruth Mackor. Met alle drie heb ik meerdere promovendi begeleid, andere projecten gedaan en heel veel interessante discussies gehad. Dank daarvoor.

De andere onderzoekers met wie ik heb samengewerkt zijn: Katie Atkinson, Jan Broersen, Jianying Cui, Frank Dignum, Jaap Dijkstra, Tom van Engers, Ad Feelders, James Freeman, Alejandro Garcia, Tom Gordon, Davide Grossi, Hans Hohmann, John Horty, Dan Ionita, Chris Janssen, Sindhu Joseph, Hendrik Kaptein, Peter van Koppen, Paul McNamara, Ronald Meester, Herre van Oostendorp, Giuseppe Pisano, Chris Reed, Silja Renooij, Régis Riveret, Bram Roth, Nino Rotolo, Guillermo Simari, Joost Schrickx, Jörgen Svensson, Kees de Vey Mestdagh, Gerard Vreeswijk, Roel Wieringa, Bin Wei, Douglas Walton, Adam Wyner,

Naast zelf onderzoek doen heb ik het begeleiden van promovendi altijd het leukste deel van mijn werk gevonden. Ik bedank daarvoor graag al mijn huidige en voormalige promovendi.

Gepromoveerd: Floris Bex, Susan van den Braak, Martin Caminada, Pieter Dijkstra, Rolf Hoving, Eric Kok, Hylke Jellema, Rudolf Rijgersberg, Mirnah Scholten, Sjoerd Timmer, Charlotte Vlek, Tom van der Weide, Remi Wieten.

Huidig: Dennis Craandijk, Daphne Odekerken, Joeri Peter, Marcel Robeer, Wijnand van Woerkom.

Ook het begeleiden van afstudeerders vind ik erg leuk werk. Met 12 van hen heb ik gepubliceerd over hun afstudeerwerk: Tim van den Belt, Floris Bex, Elfia Bezou Vrakatseli, Lianne Bodenstaff, Hugo de Bruin, Steven van Driel, Diana Grooters. Bas van Gijzel, Rosa Ratsma, Jobien Sombekke, Jelle van Veenen.

Dan mijn collega's, vroeger en nu, hier in Utrecht of elders: ik ben dankbaar dat ik altijd in veilige en inspirerende omgevingen heb gewerkt, met eigenlijk alleen maar prettige collega's, bazen en bazinnen. Nog steeds ga ik elke dag met plezier naar mijn werk; dank daarvoor.

En tot slot het thuisfront. Elke keer als ik thuiskom van mijn werk besef ik weer dat mijn gezin: Marie Ange, Patrick, Abel en Myrna, het allerbelangrijkste is in mijn leven (hoewel zij daar misschien soms anders over denken, als ze klagen dat papa weer eens te lang achter zijn computer zit). Maar het is toch echt waar.

Ik heb gezegd.

Literatuur

L. Al-Abdulkarim, K. Atkinson, T. Bench-Capon, S. Whittle, R. Williams & C. Wolfenden (2019): Noise induced hearing loss: Building an application using the ANGELIC methodology. *Argument and Computation*, 10 (2019): 5-22.

N. Aletras, D. Tsarapatsanis, D. Preotiuc-Pietro & V. Lampos (2016), Predicting judicial decisions of the European Court of Human Rights, *PeerJ Computer Science* 2016, 2:e93.

K.D. Ashley (1990), *Modeling Legal Argument: Reasoning with Cases and Hypotheticals*. Cambridge, MA: MIT Press.

K.D. Ashley & S. Brüninghaus (2009), Automatically classifying case texts and predicting outcomes. *Artificial Intelligence and Law* 17 (2009): 125–165.

K. Atkinson, P. Baroni, M. Giacomin, A. Hunter, H. Prakken, C. Reed, G. Simari, M. Thimm & S. Villata, Towards artificial argumentation. *AI Magazine* 38-3 (2017): 25-36.

T. Bench-Capon, K. Atkinson, F.J. Bex, H. Prakken & B. Verheij (2024), Computational models of legal argument. Te verschijnen in D. Gabbay, G. Kern-Isberner, G. Simari & M. Thimm (red.): *Handbook of Formal Argumentation*, Vol. 3. London: College Publications.

- B. Babic, D. Chen, T. Evgeniou & A.-L. Fayard (2020). A better way to onboard AI. *Harvard Business Review* 7-2020. URL: <https://hbr.org/2020/07/a-better-way-to-onboard-ai>.
- F.J. Bex & H. Prakken (2020), De Juridische voorspelindustrie: onzinnige hype of nuttige ontwikkeling? *Ars Aequi* 69 (2020), 255-259.
- F.J. Bex & H. Prakken (2021a), On the relevance of algorithmic decision predictors for judicial decision making. *Proceedings of the 18th International Conference on Artificial Intelligence and Law*, pp. 175-179. New York: ACM Press 2021.
- F.J. Bex & H. Prakken (2021b), Can predictive justice improve the predictability and consistency of judicial decision-making? In E. Schweighofer (ed.), *Legal Knowledge and Information Systems. JURIX 2021: The Thirty-Fourth Annual Conference*, pp. 207-214. Amsterdam etc, IOS Press (2021).
- A. Blair-Stanek, N. Holzenberger & B. van Durme (2023), Can GPT-3 perform statutory reasoning? *Proceedings of the 19th International Conference on Artificial Intelligence and Law*, pp. 22-31. New York: ACM Press 2023.
- L.K. Branting (2017), Data-centric and logic-based models for automated legal problem solving, *Artificial Intelligence and Law*, 25 (2017): 5-27.
- L.K. Branting, C. Pfeifer, B. Brown, L. Ferro, J. Aberdeen, B. Weiss, M. Pfaff & B. Liao (2021), Scalable and explainable legal prediction. *Artificial Intelligence and Law* 29 (2021): 213–238.
- J.H. Choi, K.E. Hickman, A.B. Monahan & D. Schwarcz (2023) ChatGPT goes to law school. Beschikbaar op SSRN: <https://doi.org/10.2139/ssrn.4335905>.
- M. Dahl, V. Magesh, M. Suzgun & D.E. Ho (2024), Large legal fictions: profiling legal hallucinations in large language models. *Journal of Legal Analysis* 16 (2024): 64–93.
- E. Davis & G. Marcus (2015), Commonsense reasoning and commonsense knowledge in artificial intelligence. *Communications of the ACM*, Vol. 58 No. 9, p. 92-103.
- B.M.A. van Eck (2018), *Geautomatiseerde Ketenbesluiten & Rechtsbescherming. Een Onderzoek naar de Praktijk van Geautomatiseerde Ketenbesluiten over een Financieel Belang in Relatie tot Rechtsbescherming*. Proefschrift Universiteit Tilburg. 2018.
- B.M.A. van Eck, M. Bovens & S. Zouridis (2018), Algoritmische rechtstoepassing in de democratische rechtsstaat. *Nederlands Juristenblad* 2018/2101, afl. 4, p. 3008-3017.
- F. van Eemeren & B. Verheij (2017), Argumentation theory in formal and computational perspective. In P. Baroni, D. Gabbay, M. Giacomin & L. van der Torre (red.): *Handbook of Formal Argumentation*, Vol. 1, pp. 3-73. London: College Publications, 2018.
- P.M. Freitas & L.M. Gomes (2023), Does ChatGPT pass the Brazilian bar exam? In N. Moniz et al. (red.), *Proceedings of the 22nd EPIA Conference on Artificial Intelligence (EPIA 2023)*, pp. 131-141. Springer Lecture Notes in Artificial Intelligence, vol. 14116.

- P.M. Freitas, L. Gomes & N. Moreira (2023), Does Chat-GPT pass the Portuguese bar exam? *JURIX 2023 Workshop on AI, Law and Philosophy*.
- C. Geukers (2023), Kan ChatGPT een pleitnota schrijven? *Advocatenblad* 2023-02, pp. 17-34.
- M. Gray, J. Savelka, W. Oliver & K.D. Ashley (2023a), Automatic identification and empirical analysis of legally relevant factors. *Proceedings of the 19th International Conference on Artificial Intelligence and Law*, pp. 101-110. New York: ACM Press.
- M. Gray, J. Savelka, W. Oliver & K.D. Ashley (2023b), Can GPT alleviate the burden of annotation? In G. Sileno, J. Spanakis & G. van Dijck (red.), *Legal Knowledge and Information Systems. JURIX 2023: The Thirty-Sixth Annual Conference*, pp. 157-166. Amsterdam etc, IOS Press (2023).
- N. Guha et al. (2023), LEGALBENCH: a collaboratively built benchmark for measuring legal reasoning in large language models. *Advances in Neural Information Processing Systems* 36 (2023), 44123-44279.
- U. Hahn (2020), Argument quality in real world argumentation. *Trends in Cognitive Science* 24 (2020): 363-374.
- M. Hinton & J.H.M. Wagemans (2022), How persuasive is AI-generated argumentation? An analysis of the quality of an argumentative text produced by the GPT-3 AI text generator. *Argument and Computation* 14 (2022): 59-74.
- V. Hofmann, P. R. Kalluri, D. Jurafsky & S. King (2024), Dialect prejudice predicts AI decisions about people's character, employability, and criminality. arXiv:23403.00742
- Xinyu Hua and Lu Wang. 2018. Neural argument generation augmented with externally retrieved evidence. *Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics* (Vol. 1: Long Papers), 219–230.
- J. Huang & K. Ch-Ch. Chang (2023), Towards reasoning in large language models: a survey. In *Findings of the Association for Computational Linguistics: ACL 2023*, pages 1049–1065, Toronto, Canada. Association for Computational Linguistics.
- K.Y. Iu & V.M-Y. Wong (2023), ChatGPT by OpenAI: the end of litigation lawyers? Beschikbaar op SSRN: <https://ssrn.com/abstract=4339839>
- F. Jensma (2017), Big data kunnen de rechter verdringen. NRC 28 oktober 2017.
- C. Jiang & X. Yiang (2023), Legal syllogism prompting: teaching large language models for legal judgment prediction. *Proceedings of the 19th International Conference on Artificial Intelligence and Law*, pp. 417-421. New York: ACM Press 2023.
- X. Kang, L. Qu, L-K. Soon, A. Trakic, T.Y. Zhuo, P.C. Emerton & G. Grant (2023), Can ChatGPT perform reasoning using the IRAC method in analyzing legal scenarios like a lawyer? ArXiv:2310.14880
- D.M. Katz, M.J. Bommarito, S. Gao & P. Arredondo (2023), GPT-4 passes the bar exam. Beschikbaar op SSRN: <https://ssrn.com/abstract=4389233> Definitieve versie in *Philosophical Transactions of the Royal Society A, Mathematical, Physical and Engineering Sciences*. Vol. 382, issue 2270. <https://doi.org/10.1098/rsta.2023.0254>

- V. Magesh, F. Surani, M. Dahl, M. Suzgun, C.D. Manning & D.E. Ho (2024), Hallucination-free? Assessing the reliability of leading AI legal research tools. ArXiv:2405.20362
- E. Martínez (2024) Re-evaluating GTP-4's bar exam performance. *Artificial Intelligence and Law*, <https://doi.org/10.1007/s10506-024-09396-9>.
- M. Medvedeva, M. Vols & M. Wieling (2020), Using machine learning to predict decisions of the European Court of Human Rights, *Artificial Intelligence and Law* 28 (2020): 237-266.
- M. Medvedeva, M. Vols & M. Wieling (2023), Rethinking the field of automatic prediction of court decisions, *Artificial Intelligence and Law* 31 (2023): 195-212.
- S.J. Modgil & H. Prakken (2013), A general account of argumentation with preferences. *Artificial Intelligence* 195 (2013): 361-397.
- J.J. Nay, D. Karamardian, S.B. Lawskey, W. Tao, M. Bhat, R. Jain, A. Travis Lee, J.H. Choi & J. Kasai (2024), Large language models as tax attorneys: a case study in legal capabilities emergence. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, Vol. 382, issue 2270. <https://doi.org/10.1098/rsta.2023.0159>
- D. Odekerken & F.J. Bex (2020), Towards transparent human-in-the-loop classification of fraudulent web shops. In S. Villata, J. Harašta & P. Křemen (red.), *Legal Knowledge and Information Systems. JURIX 2020: The Thirty-Third Annual Conference*, pp. 239-242. IOS Press, Amsterdam etc. 2020.
- D. Odekerken, F.J. Bex & H. Prakken (2023), Precedent-based reasoning with incomplete cases. In G. Sileno, J. Spanakis & G. van Dijck (red.), *Legal Knowledge and Information Systems. JURIX 2023: The Thirty-Sixth Annual Conference*, pp. 33-42. IOS Press, Amsterdam etc. 2023.
- C. Panigutti, R. Hamon, I. Hupont, D. Fernandez Llorca, D. Fano Yela & H. Junklewitz (2023), The role of explainable AI in the context of the AI Act. *Proceedings of the 2023 ACM Conference on Fairness, Accountability, and Transparency (FAccT '23)*, pp. 1139-1150. New York: ACM Press.
- F. Pasquale & G. Cashwell (2018). Prediction, persuasion, and the jurisprudence of behaviourism. *University of Toronto Law Journal* 68, supplement 1 (2018), 63–81.
- A.M. Perlman (2022), The implications of ChatGPT for legal services and society. Beschikbaar op SSRN: <http://ssrn.com/abstract=4294197>.
- H. Prakken (1993), A logical framework for modelling legal argument. *Proceedings of the Fourth International Conference on Artificial Intelligence and Law*, pp. 1-9. New York: ACM Press.
- H. Prakken (2005), Argumentatiemanagement voor Juristen. Inaugurele rede Faculteit der Rechtsgeleerdheid, Rijksuniversiteit Groningen.
- H. Prakken (2010), An abstract framework for argumentation with structured arguments. *Argument and Computation* 1 (2010): 93-124.
- H. Prakken (2015), Legal reasoning: computational models, in J.D. Wright (ed.) *International Encyclopedia of the Social and Behavioural Sciences*, 2nd edition. Oxford: Elsevier Ltd.

- H. Prakken (2018), Komt de Robotrechter er aan? *Nederlands Juristenblad* 2018/207, no. 4, pp. 269-274.
- H. Prakken (2021), Logical models of legal argumentation. In M. Knauff & W. Spohn (red.): *The Handbook of Rationality*, pp. 669-677. Cambridge, MA: MIT Press 2021.
- H. Prakken (2024), On evaluating legal-reasoning capabilities of generative AI. In *Proceedings of the 24th Workshop on Computational Models of Natural Argument*, Hagen (Germany), 17 September 2024. CEUR-WS, te verschijnen.
- H. Prakken & G. Sartor (1996), A dialectical model of assessing conflicting arguments in legal reasoning. *Artificial Intelligence and Law* 4 (1996): 331-368.
- H. Prakken & G. Sartor (2015), Law and logic: a review from an argumentation perspective. *Artificial Intelligence* 227 (2015): 214-245.
- G. Sartor (2005), *Legal Reasoning: a Cognitive Approach to the Law*. Vol. 5 van E. Pattaro (red.), *Treatise on Legal Philosophy and General Jurisprudence*. Berlin: Springer.
- M. Schraagen, B. Testerink, D. Odekerken & F.J. Bex (2018), Argumentation-driven information extraction for online crime reports. *CKIM 2018 International Workshop on Legal Data Analysis and Mining (LeDAM 2018)*, *CEUR Workshop Proceedings*, 2482.
- S. Servantez, J. Barrow, K. Hammond & R. Jain (2024), Chain of logic: rule-based reasoning with large language models. arXiv:2402.10400.
- J. Susskind (2018), *Future Politics: Living Together in a World Transformed by Tech*, Oxford: Oxford University Press 2018.
- J.S. Svensson (2002), The use of legal expert systems in administrative decision making. In A. Grönlund (red.), *Electronic Government: Design, Applications and Management*, London etc.: Idea group publishing.
- A. Trozze, T. Davies & B. Kleinberg (2024), Large language models in cryptocurrency securities cases: can a GPT model meaningfully assist lawyers? *Artificial Intelligence and Law*, <https://doi.org/10.1007/s10506-024-09399-6>
- M. Turpin, J. Michael, E. Perez & S.R. Bowman (2023), Language models don't always say what they think: unfaithful explanations in chain-of-thought prompting. *Advances in Neural Information Processing Systems* 36 (2023).
- B. Verheij (2018), Argumenten voor Goede Kunstmatige Intelligentie. Inaugurele rede Faculteit Science and Engineering, Rijksuniversiteit Groningen.
- H. Wachsmuth, N. Naderi, I. Habernal, Y. Hou, G. Hirst, I. Gurevych & B. Stein (2017), Argumentation quality assessment: theory and practice. *Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics*, (Vol. 2: short papers), 250–255.
- J. Wei, X. Wang, D. Schuurmans, M. Bosma, B. Ichter, F. Xia, E. Chi, Q. Le & D. Zhou (2022), Chain-of-thought prompting elicits reasoning in large language models. ArXiv:2201.11903.
- F. Yu, L. Quartey & F. Schilder (2022) Legal prompting: teaching a language model to think like a lawyer. arXiv:2212.01326.