BUSINESS In-zicht

N° 20 • NOVEMBER 2005

EEN BERICHT OVER ONDERZOEK AAN HET DEPARTEMENT TOEGEPASTE ECONOMISCHE WETENSCHAPPEN VAN DE KATHOLIEKE UNIVERSITEIT LEUVEN

IN DIT NUMMER

AntMiner+ Een Systeem van Kennis-Ontginnende Mieren

RAF HAESEN, DAVID MARTENS, MANU DE BACKER, BART BAESENS

DE IMMENSE OPSLAGCAPACITEIT DIE BEDRIJVEN VANDAAG DE DAG TER BESCHIKKING HEBBEN, BEVAT DIKWIJLS EEN KLUWEN VAN RUWE DATA WAARIN WAARDEVOLLE KENNIS ZICH SCHUIL HOUDT. DATA MINING OMVAT HET ONTGINNEN VAN DEZE VERBORGEN KENNIS OP EEN GEAUTOMATISEERDE WIJZE. VEELAL WORDT HIERBIJ ACCURAATHEID ALS ENIGE PERFORMANTIE-INDICATOR GEHANTEERD. DOCH BEGRIJPBAARHEID KAN TEVENS EEN KRITISCHE VEREISTE ZIJN IN DOMEINEN ZOALS MEDISCHE DIAGNOSESTELLING EN CREDIT SCORING. DE VOORGESTELDE TECHNIEK, ANTMINER+, IS GEÏNSPIREERD OP HET GEDRAG VAN MIEREN EN RICHT ZICH OP HET EXTRAHEREN VAN DERGELIJKE ACCURATE ÉN BEGRIJPBARE MODELLEN.

VAN BIOLOGISCHE TOT ARTIFICIËLE MIERENSYSTEMEN

Individuele mieren zijn eenvoudige insecten met gelimiteerd geheugen en vermogen om acties te ondernemen. Een mierenkolonie daarentegen vertoont zeer complex gedrag en kan intelligente oplossingen vinden voor problemen zoals het transporteren van grote voorwerpen en het vinden van de kortste weg tussen een voedselbron en het mierennest. Het intelligente gedrag, "emergent behavior" genoemd, vloeit voort uit de zelforganisatie en indirecte communicatie tussen de mieren. Mieren communiceren door middel van feromonen: een mier laat deze chemische substantie achter op het pad dat hij volgt. Omdat mieren in staat zijn de aanwezigheid van deze substantie waar te nemen, ontstaat indirecte communicatie met de andere mieren. Immers, hoe hoger het feromoongehalte van het pad, des te groter de kans dat de mier dit pad zal kiezen. Vermits de mieren op het kortste pad meer feromonen per tijdseenheid kunnen afscheiden, zal na verloop van tijd enkel dit pad versterkt worden en gekozen worden door de mieren.

Laat ons dit verduidelijken met Figuur 1. Twee mieren zijn op weg naar een voedselbron; initieel is er geen feromoon op de paden en is de kans dat de mieren het bovenste of het onderste pad kiezen gelijk. De mier die het onderste pad heeft gekozen is sneller terug bij het nest, waardoor er dubbel zoveel feromonen op dit pad liggen dan op het bovenste pad. Hierdoor is de kans dat een volgende mier het onderste, kortere pad kiest dubbel zo groot waardoor er nog meer mieren dit pad zullen kiezen, zodat uiteindelijk (bijna) alle mieren het kortste pad zullen volgen.

FIGUUR 1. PADSELECTIE BIJ MIEREN OP BASIS VAN FEROMONEN

Artificiële mierenkolonies zijn gebaseerd op biologische mierenkolonies en bestaan uit zeer simpele software agenten, die net zoals mieren slechts een beperkt geheugen en vermogen hebben [3]. Een dergelijk systeem is parallel en gedistribueerd, gezien de agenten in de populatie simultaan en onafhankelijk van elkaar bewegen, en dit zonder enige hogere instantie die bevelen geeft. De agenten bewegen stochastisch op basis van twee parameters, het feromoongehalte en een heuristische waarde. Het feromoongehalte geeft aan hoeveel agenten het spoor recentelijk hebben gevolgd, en de heuristische waarde is een probleemafhankelijke parameter. Als een agent aankomt op een beslissingspunt, heeft het pad met het hoogste feromoongehalte en de grootste heuristische waarde de meeste kans gekozen te worden. Eens alle agenten aangekomen zijn in de eindbestemming, wordt de omgeving aangepast: ten eerste daalt het feromoongehalte op alle paden door verdamping en ten tweede wordt het pad van de beste agent versterkt door het feromoongehalte te verhogen. Een nieuwe iteratie van begin tot einde begint vervolgens. Heel dit proces wordt herhaald tot de agenten convergeren naar een (sub)optimale oplossing van het probleem.

DATA MINING: HET INFEREREN VAN KENNIS UIT EEN OVERVLOED VAN DATA

De groeiende populariteit van het Internet en de recentelijk technologische vooruitgang op het vlak van dataopslag hebben geleid tot een ware explosie van ongestructureerde data. Het distilleren van bruikbare patronen uit deze almaar groeiende stroom van ruwe data vormt een bedrijfskritische uitdaging binnen onze kenniseconomie. Data mining beoogt het extraheren van dergelijke kennis op een geautomatiseerde wijze. Classificatie is een onderdeel van data mining en omvat het toekennen van datapunten aan een bepaalde klasse op basis van specifieke kenmerken. Hiervoor wordt een beroep gedaan op een hoeveelheid van beschikbare data met gekende klasse. Classificatieproblemen doen zich voor in tal van domeinen, zoals medische diagnosestelling, fraudedetectie, credit scoring en het voorspellen van aankoopprofielen in de marketing sector. Het resultaat van een classificatietechniek is een beslissingsmodel waarmee toekomstige datapunten kunnen toegewezen worden aan een bepaalde klasse.

(Vervolg op pag. 4)

(Vervolg van pag. 1)

De performantie van een model wordt typisch gemeten door diens accuraatheid op een onafhankelijke dataset. Niet-lineaire classificatietechnieken, zoals neurale netwerken en support vector machines scoren het best volgens dit criterium [1], maar begrijpbaarheid van de gegenereerde modellen is ook een belangrijke vereiste. In de financiële sector bijvoorbeeld moeten kredietverleners een duidelijke reden kunnen voorleggen waarom krediet geweigerd wordt aan een klant, vage redenen zijn hierbij uit den boze! Onze aanpak houdt hiermee rekening en focust zich op het genereren van accurate én begrijpbare classificatiemodellen.

Het doel is om eenvoudige "als-dan-anders" regels af te leiden uit de data, waarbij het conditiegedeelte bestaat uit de conjunctie van een aantal termen. Elke term beschrijft ofwel een discrete waarde van een variabele, ofwel een continu interval van waarden. Daarom is elke term van de vorm *"Variabele = Waarde"*, ofwel *"Variabele ≤ Waarde"*, ofwel "*Variabele ≥ Waarde*". Een voorbeeldregel bij kredietverlening is: "***als** Inkomen ≥ €10.000 **en** gehuwd = ja **dan** kredietwaardig = ja **anders** kredietwaardig = nee*".

De Link Tussen Mieren en Data Mining in AntMiner+

In de voorgestelde aanpak wordt de oplossingsstrategie van een artificiële mierenkolonie toegepast op het classificatieprobleem [2]. De omgeving waarin de mieren bewegen, wordt voorgesteld door een gerichte, acyclische graaf zoals in Figuur 2. Voor elke variabele definiëren we een groep van knopen waarbij elke knoop een bepaalde waarde van die variabele voorstelt. Mieren die zich in een knoop van een bepaalde variabele bevinden, mogen enkel naar knopen van de volgende variabele gaan. Elke mier vertrekt in de startknoop met een lege regel en voegt in elke bezochte knoop een term aan de regel toe. Aangekomen in de eindknoop, beschrijft de mier een volledige regel.

Om regels toe te laten die niet alle variabelen omvatten, wordt aan elke variabele een dummyknoop toegevoegd die eender welke waarde van de variabele aanneemt. Als een dergelijke knoop bezocht wordt, betekent dit dat de bijhorende variabele irrelevant is voor de classificatie en kan deze weggelaten worden uit de regel. Dit geeft aanleiding tot kortere en dus eenvoudigere regels. Het pad op de figuur dat vet staat aangeduid, beschrijft daarom de regel: "***als** Geslacht = Man **en** Doel Lening = Huis **dan** Klant = Goed*".

Figuur 2. Constructie graaf met 3 variabelen

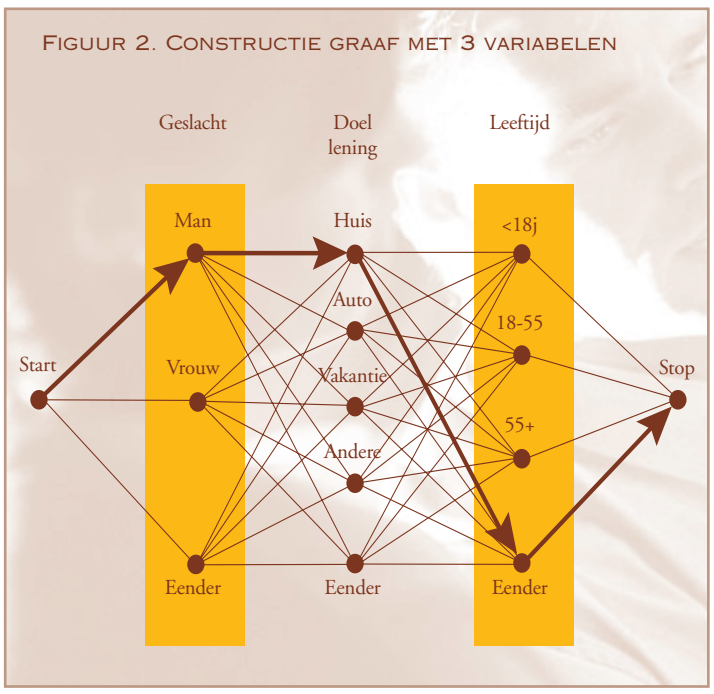

Gedistribueerde Data Mining met AntMiner+

Om het gebruik van AntMiner+ in een dynamische en gedistribueerde omgeving aan te tonen, hebben we een typische case uit de financiële wereld uitgewerkt, zie Figuur 2. De vraag of een klant al dan niet een lening mag aangaan, komt typisch neer op een binair classificatieprobleem om de betrouwbare betalers te onderscheiden van de onbetrouwbare. Stel dat een bank AntMiner+ wil gebruiken om een begrijpbaar model te construeren, waarmee beslissingen rond kredietwaardigheid kunnen verantwoord worden. De bank heeft allerlei klantgegevens ter beschikking zoals de saldo's van zichtrekeningen en spaarrekeningen. Ook heeft ze toegang tot data van een kredietbureau dat informatie van verschillende financiële instellingen consolideert. Andere bronnen van nuttige informatie zijn het rijksregister en het kadaster. Een gecentraliseerde aanpak zou heel wat dataverkeer over het netwerk veroorzaken en de verwerking zou moeizaam te realiseren zijn. AntMiner+ daarentegen stuurt mieren over het netwerk naar de relevante databases. De omgeving wordt dynamisch geconstrueerd over de verschillende sites, waarbij elke database een aantal variabelen bevat.

De gedecentraliseerde aanpak die hier voorgesteld wordt, maakt het mogelijk om op een snelle manier profielen van wanbetalers te ontdekken. Bovendien is de voorgestelde oplossing gemakkelijk schaalbaar en foutbestendig: mieren die verdwalen in het netwerk, of zelfs verbroken dataconnecties verlagen de performantie niet en AntMiner+ kan toch nog correct functioneren.

Figuur 3. AntMiner+ in een gedistribueerde omgeving

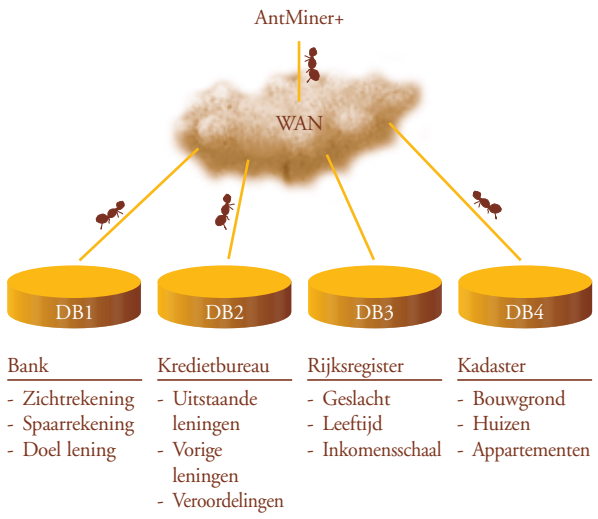

AntMiner+ werd toegepast op dergelijke datasets voor kredietvoorspelling. De geëxtraheerde classificatiemodellen zijn performant en begrijpbaar. Een voorbeeld van een set regels gegenereerd door AntMiner+ is te vinden in Tabel 1.

Tabel 1. "Als-dan-anders" regels geëxtraheerd door AntMiner+

als (saldo zichtrekening < 100 EUR **en** duur > 15 M **en** krediet geschiedenis = geen **en** saldo spaarrekening < 500 EUR)
dan klant = slecht
anders als (doel = nieuwe auto/herstelling/onderwijs/ andere **en** krediet geschiedenis = geen/alle schulden afgelost in deze bank **en** saldo spaarrekening < 500 EUR)
dan klant = slecht
anders als (saldo zichtrekening < 0 EUR **en** doel = meubelen/huisraad/zaken **en** krediet geschiedenis = geen/alle schulden afgelost in deze bank **en** saldo spaarrekening < 250 EUR)
dan klant = slecht
anders als (saldo zichtrekening < 0 EUR **en** duur > 15 M **en** krediet geschiedenis = vertraging bij afbetalingen in het verleden **en** saldo spaarrekening < 250 EUR)
dan klant = slecht
anders klant = goed

Conclusie

AntMiner+ is een techniek die de gedragsprincipes van mieren succesvol toepast op data mining. Niettegenstaande de beperkte mogelijkheden van een individuele mier, slaagt een AntMiner+ mierenkolonie erin om accurate, complexe, doch begrijpbare classificatiemodellen te ontginnen, die onmiddellijk inzetbaar zijn in het bedrijfsproces.

Raf Haesen *is als wetenschappelijk medewerker verbonden aan de KBC leerstoel in samenwerking met de Vlekho en de K.U.Leuven.*
raf.haesen@econ.kuleuven.be

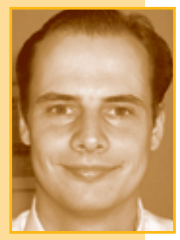

David Martens *is als wetenschappelijk medewerker verbonden aan het LIRIS-onderzoekscentrum in de Beleidsinformatica aan de Faculteit ETEW.*
david.martens@econ.kuleuven.be

Manu De Backer *is als wetenschappelijk medewerker verbonden aan het LIRIS-onderzoekscentrum in de Beleidsinformatica aan de Faculteit ETEW. Zijn onderzoek wordt gefinancierd door de Microsoft Research Chair.*
manu.debacker@econ.kuleuven.be

Bart Baesens *is deeltijds docent aan de Faculteit ETEW en lecturer (assistant professor) aan de School of Management, University of Southampton (United Kingdom).*
bart.baesens@econ.kuleuven.be

Referenties:

- [1] B. Baesens, T. Van Gestel, S. Viaene, M. Stepanova, J. Suykens, and J. Vanthienen. Benchmarking state-of-the-art classification algorithms for credit scoring. *Journal of the Operational Research Society*, 54(6):627–635, 2003.
- [2] M. De Backer, R. Haesen, D. Martens, and B. Baesens. A Stigmergy Based Approach to Data Mining, Proceedings of the Joint Australian Conference on Artificial Intelligence, *Lecture Notes in Computer Science*, accepted for publication, 2005.
- [3] M. Dorigo, V. Maniezzo, and A. Colorni. Positive feedback as a search strategy. Technical Report 91016, Dipartimento di Elettronica e Informatica, Politecnico di Milano, IT, 1991.

V.U. Filip Roodhooft, Naamsestraat 69, B-3000 Leuven, Katholieke Universiteit Leuven, Departement Toegepaste Economische Wetenschappen, België