

Datakwaliteit (E018700)

Cursusomvang *(nominale waarden; effectieve waarden kunnen verschillen per opleiding)*

Studiepunten 3.0 **Studietijd 90 u**

Aanbodsessies in academiejaar 2023-2024

A (semester 1) Engels Gent

Lesgevers in academiejaar 2023-2024

Bronselaer, Antoon TW07 Verantwoordelijk lesgever

Aangeboden in onderstaande opleidingen in 2023-2024

	stptn	aanbodsessie
Brugprogramma Master of Science in Bioinformatics (afstudeerrichting Engineering)	3	A
Master of Science in Business Engineering (afstudeerrichting Data Analytics)	3	A
Master of Science in Bioinformatics (afstudeerrichting Engineering)	3	A
Master of Science in Business Engineering (Double Degree) (afstudeerrichting Operations Management)	3	A
Master of Science in Business Engineering (afstudeerrichting Operations Management)	3	A
Master of Science in Computer Science Engineering	3	A
Master of Science in de industriële wetenschappen: informatica	3	A
Master of Science in de informatica	3	A
Uitwisselingsprogramma industriële wetenschappen: informatica	3	A
Uitwisselingsprogramma informatica (niveau master)	3	A

Onderwijstalen

Engels

Trefwoorden

Meten van datakwaliteit, consistentie, detectie en herstel van fouten, outlier detection

Situering

Deze cursus is een specialisatiecursus waarin mechanismen voor het waarborgen van datakwaliteit centraal staan. Een eerste deel van de cursus behandelt verschillende methoden voor het meten van kwaliteit. In een tweede deel komen algoritmen aan bod die toelaten om fouten te detecteren, alsook algoritmen om deze fouten systematisch te gaan corrigeren. Een derde deel behandelt ontdebbling van data. Een vierde deel behandelt het detecteren van outliers en tot slot bekijken we in een vijfde en laatste deel een aantal specifieke kwaliteitsproblemen bij temporele data.

Inhoud

- Inleiding tot datakwaliteit
- Meten van datakwaliteit: ordinale systemen, onzekerheidsmodellen en kost-gebaseerd meten
- Basis van constraint-gebaseerde formalismen
- Controle getallen
- Edit regels: foutlocalisatie, Fellegi-Holt model, FCF-algoritme
- Chase algoritme voor functionele afhankelijkheden
- Data ontdebbling: Fellegi-Sunter model, string vergelijking, samenvoegen van dubbele data
- Outlier detectie: afstandsgebaseerde modellen, pivot index, ruimtelijke partitionering, isolation forests,
- Datakwaliteit in temporele data: trend decompositie, change detection, currency

Begincompetenties

Vertrouwd zijn met gegevensstructuren en een basiservaring hebben met relationele databanken. Basiskennis van programmeren

(Goedgekeurd)

Eindcompetenties

- 1 Inzicht hebben in de basistechnieken voor het meten van datakwaliteit.
- 2 Begrijpen hoe consistentie kan worden afgedwongen en in staat zijn om dit toe te passen.
- 3 Begrijpen hoe een dataset kan worden ontdekt.
- 4 Begrijpen hoe outliers gezocht kunnen worden.
- 5 Inzicht hebben in de specifieke kwaliteitsproblemen bij temporele data.

Creditcontractvoorwaarde

Toelating tot dit opleidingsonderdeel via creditcontract is mogelijk mits gunstige beoordeling van de competenties

Examencontractvoorwaarde

Dit opleidingsonderdeel kan niet via examencontract gevolgd worden

Didactische werkvormen

Werkcollege, Hoorcollege

Leermateriaal

- Slides
- Bijkomend leermateriaal beschikbaar via Ufora (artikels, kennisclips)

Referenties

- Ton De Waal, Jeroen Pannekoek en Sander Scholtus (2011). Handbook of Statistical Data Editing and Imputation, Wiley
- Wenfei Fan en Floris Geerts (2012). Foundations of Data Quality Management. Morgan & Claypool Publishers.

Vakinhoudelijke studiebegeleiding

Alle oefeningenlessen worden begeleid door assistenten.

Evaluatiemomenten

periodegebonden evaluatie

Evaluatievormen bij periodegebonden evaluatie in de eerste examenperiode

Schriftelijke evaluatie

Evaluatievormen bij periodegebonden evaluatie in de tweede examenperiode

Schriftelijke evaluatie

Evaluatievormen bij niet-periodegebonden evaluatie

Tweede examenkans in geval van niet-periodegebonden evaluatie

Niet van toepassing

Toelichtingen bij de evaluatievormen

Periodegebonden evaluatie: schriftelijk open boekexamen met open vragen die naar inzicht in de cursus peilen.

Eindscoreberekening

100% schriftelijk examen met open boek.