

Eignungsdiagnostik durch Predictive Analytics mit Fokussierung auf maschinellem Lernen am Beispiel von Studienerfolgspotenzialen zukünftiger Softwareentwickler

Masterthesis im Studiengang

M.Sc. Wirtschaftsinformatik / IT-Management

an der NORDAKADEMIE gemeinnützige AG,

private Hochschule der Wirtschaft,

in 25337 Elmshorn,

vorgelegt von

B.Sc. Dirk Johannßen

Alsterdorfer Str. 127

22299 Hamburg

MWINF15a - 6738

Tel.: 0160 / 906-75461

Erstgutachter : Prof. Dr. Nick Gehrke

Zweitgutachter : Prof. Dr. Hinrich Schröder

Bearbeitungszeit : 31. Oktober 2016 bis 30. März 2017

Inhaltsverzeichnis

Abbildungsverzeichnis	IV
Tabellenverzeichnis	V
Glossar	VI
Nomenklatur	VII
1. Einleitung und Problemstellung	1
1.1. Thematische Einleitung	2
1.2. Problemstellung und Forschungslücke	3
1.3. Hypothesenbildung	4
1.4. Aufbau und Vorgehen	6
2. Studieneignungsdiagnostik	8
2.1. Öffnung für hochschuleigene Auswahlverfahren im Hochschulgesetz	8
2.2. Abgrenzung zur Eignungsdiagnostik des Personalwesens	9
2.3. Verständnis von Erfolg und Misserfolg in der Studieneignungsdiagnostik	10
2.4. Gängige eignungsdiagnostische Verfahren	11
2.5. Nordakademie-Auswahltest	12
3. Bayessche Netze	17
3.1. Graphentheorie	17
3.2. Wahrscheinlichkeitstheorie und bedingte Wahrscheinlichkeiten	18
3.3. Inferenzen	20
3.4. Satz von Bayes	21
3.5. Lernalgorithmen für Struktur und Parameter	22
4. Entwicklung eines Expertensystems	26
4.1. Auswahl geeigneter Module als Leistungsindikatoren zukünftiger Softwareentwickler	26
4.2. Datenerhebung und statistische Voruntersuchung	30

4.3.	Erstellung von Korrelationstabellen und deren Interpretation	51
4.4.	Modellierung durch MSBNx	54
4.5.	Experteninterviews	56
4.6.	Manuelle Struktur und Parameterlernen durch R und bnlearn	60
5.	Empirische Erprobung und Ergebnisanalyse	65
5.1.	Iterative Verbesserung	65
5.2.	Bestes Bayessches Netz	66
5.3.	Befragung anhand von Testdaten	69
5.4.	Eignungsevaluation	74
6.	Kritische Eignungsdiskussion und Handlungsempfehlung	76
6.1.	Zusammenfassung der bisherigen Ergebnisse	76
6.2.	Beantwortung der Hypothesen	77
6.3.	Ableitung einer allgemeingültigen Handlungsempfehlung für ähnliche Problemstellungen	79
6.4.	Fazit und Ausblick	80
	Literatur	81
A.	Anhang	88
A.1.	Datenbasis	88
A.2.	Historisches Hintergrundwissen: Entwicklung der KI und Paradigmenwechsel in der Studieneignungsdiagnostik	89
A.3.	Vollständige Testdatensätze	98
A.4.	Ausgewählte Scatterplots	101
A.5.	Korrelationstabellen	106
A.6.	Beispielrechnung zu einem Bayesschen Netz	108
A.7.	Code-Listings	110
A.8.	Leitfaden für Experteninterviews	112
A.9.	Hybrides Bayessches Netz im Detail	114
A.10.	Modulbeschreibungen	118
B.	Anlagen	131
	Eidesstattliche Erklärung	132

Abbildungsverzeichnis

1.	Frage aus dem MIX-Katalog	13
2.	Frage aus dem ViQ-Katalog	14
3.	Frage aus dem IQt-Katalog	16
4.	Gerichteter azyklischer Graph (DAG)	18
5.	Struktur eines Bayesschen Netzes	22
6.	Venn-Diagramm mit binären Mengen- und Schnittmengenbezeichnern	27
7.	Scatterplots mit Regressionsgeraden	41
8.	Ausschnitt einer Korrelationstabelle	52
9.	Auf Basis der Korrelationstabelle ermittelte Korrelationen	53
10.	Identifizierung möglicher 'Mittler'	54
11.	Durch das Programm MSBNx modelliertes Bayes-Netz zur Evaluation durch Experten	55
12.	Durch den MMHC erlernte BN-Struktur	62
13.	Struktur des hybriden BNs	67
14.	Stärke der Arcs als Schema	68
15.	MENACE-Schema	91
16.	Scatterplot Modul- und Oberstufenergebnisse	102
17.	Scatterplot Modul- und NAK-Mathematik-Test-Ergebnisse	103
18.	Scatterplot Modul- und IQt-Ergebnisse	104
19.	Scatterplot Modul- und MIX-Leistungs-Ergebnisse	105
20.	Scatterplot Modul- und ViQ-Thinking-Ergebnisse	106
21.	Erster Ausschnitt der Korrelationstabelle	107
22.	Zweiter Ausschnitt der Korrelationstabelle	108
23.	Beispiel eines Bayesschen Netzes	109
24.	Struktur des hybriden BNs	115
25.	Stärke der Arcs als Schema	116

Tabellenverzeichnis

1.	Beispiel einer Tabelle mit vollständiger gemeinsamer Verteilung	20
2.	Modul- und Qualifikationsziele als Schnittmenge zu den Kompetenzen zukünftiger Softwareentwickler der Studiengänge Angewandte Informatik (AInf) und Wirtschaftsinformatik (WInf).	28
3.	Modul- und Qualifikationsziele als Schnittmenge zu den Kompetenzen zukünftiger Softwareentwickler der Studiengänge Wirtschaftsingenieurwesen (WIng) und Betriebswirtschaftslehre (BWL).	28
4.	Auszug eines reduzierten Datensatzes. Es fehlen drei Betrachtungsmodul je eines Studierenden	32
5.	Auswahl geeigneter Module als Leistungsindikatoren des logischen Denkvermögens.	33
6.	Werte-Typen und zugehörige Skalen	34
7.	Multiple Regression ohne Notenwerte	43
8.	Multiple Regression mit Notenwerten	43
9.	Univariate Maßzahlen	45
10.	Bivariate Maßzahlen	47
11.	Auswahl geeigneter Module als Leistungsindikatoren des logischen Denkvermögens.	57
12.	Notenschema ausgewählter Testdatensätze	69
13.	Kompletter Datensatz in Rohform. Die Kahnemann-Werte fehlten.	88

Glossar

Bayes-Netze Gerichteter azyklischer Graph zur kompakten Darstellung bedingter Abhängigkeiten (Russell und Norvig 2012, vgl. S. 843f).

Ego-Involvement „Betroffenheit einer Person durch Relevanz der Stimuli für die eigene Selbstidentität“ (Sherif (1966, vgl. S. 92-116) zitiert durch Sarges und Scheffer (2008, S. 17)) .

Expertensystem Ein System, welches wie ein menschlicher Experte auf Grundlage einer Wissensbasis und der Fähigkeit, Schlüsse und Inferenzen zu ziehen, nach einer Meinung oder Einschätzung gefragt werden kann (Russell und Norvig 2012, vgl. S. 737).

Künstliche Intelligenz KI, wie es in dieser Arbeit genutzt wird, versteht sich als eine maschinelle Nachempfindung *menschlichen Handelns oder Denkens*, bei denen menschliches Verhalten nachempfunden wird. KI kann ferner aufgefasst werden als maschinelle Nachempfindung *Rationalen Denkens oder Handelns*, bei denen möglichst optimale Ergebnisse erzielt werden (ebd., Vgl. S. 32).

Maschinelernen Die Eigenschaft, „sich an neue Umstände anzupassen sowie Muster zu erkennen und zu extrapolieren“ (ebd., S. 23).

MIX-Motive Nach Sarges und Scheffer (2008) handelt es sich bei den MIX-Motiven um Wollensfaktoren, die für jeden Menschen unterschiedlich ausfallen.

Predictive Analytics Das Schließen auf Zukunftstrends auf Basis der Analyse von Vergangenheitswerten (Elkan 2013, vgl. S.25).

Visual Questionnaire Der ViQ ist ein optischer Test, der Persönlichkeitsmerkmale anhand der Interpretation visueller Zeichen bestimmt (Sarges und Scheffer 2008, Vgl. S. 52ff).

Nomenklatur

\bar{x}	Arithmetisches Mittel, Seite 36
χ^2	Chi-Quadrat-Unabhängigkeitstest, Seite 38
μ	Erwartungswert, Seite 34
ω	Ergebnismenge der Wahrscheinlichkeitsrechnung, Seite 18
ϕ	Probabilistische Behauptung, Seite 18
ρ	Korrelationskoeffizient, Seite 38
σ	Standardabweichung, Seite 34
σ^2	Varianz, Seite 37
Θ	Klassenzugehörigkeit aller ähnlichartigen Verteilungen, Seite 23
\tilde{x}	Median oder Mittelwert, Seite 36
$cov_{x,y}$	Kovarianz der Variablen x und y, Seite 37
R^2	Bestimmtheitsmaß, Seite 39
AC	Assessment Center, Seite 11
BN	Bayessches Netz, Seite 17
CPT	Conditional Probability Table (Wahrscheinlichkeitstabelle), Seite 23
DAG	Directed Acyclic Graph (Gerichteter azyklischer Graph), Seite 17
EM	Expectation-Maximization, Seite 23
IQ _t	Technischer Intelligenz-Quotient, Seite 15
MMHC	Max-Min Hill-Climbing, Seite 23
MMPC	Max-Min Parents and Children, Seite 23
NN	Neuronales Netz, Seite 2
TMS	Test für medizinische Studiengänge, Seite 9
ViQ	Visual Questionnaire. Dimensionen: Thinking (t), Intuition (n), Feeling (f), Judging (j), Sensing (s), Extraversion (e), Seite 14

1. Einleitung und Problemstellung

Die Anfänge aktueller Themen wie *Maschinelles Lernen*, *Künstliche Intelligenz* oder *Probabilistisches Schließen* gehen auf die Zeit des Zweiten Weltkriegs zurück. Noch heute zeichnet sich das wissenschaftliche Gebiet der Künstlichen Intelligenz (KI) durch neue Erkenntnisse und Erfolge aus, wie es z.B. die Durchbrüche im Computer-GO zeigen (Silver u. a. 2016, vgl. S. 484).

Im Zuge technologischer Erfolge auf dem Gebiet der Künstlichen Intelligenz (KI) wird sich aktuell mit der Suche nach geeigneten Anwendungsgebieten beschäftigt. Die Personalakquise ist für Unternehmen des Informations- und Telekommunikationstechnologischen Sektors (ITK) zu einer kritischen Kernkompetenz im Konkurrenzkampf geworden. Duale Studien sind in Deutschland weit verbreitet und werden von ITK-Unternehmen als Chance der Personalgewinnung gesehen. Geeignete Studieninteressierte zu identifizieren, erfordert oft aufwendige Auswahlverfahren. Der Investition in diese Ausbildung stehen hohe Abbrecherquoten unter Studierenden der Studiengänge aus Mathematik, Informatik, Naturwissenschaften und Technologie (MINT) gegenüber.

Um die Bedeutung der modernen Forschung für die Gegenwart und die Zukunft nachvollziehen zu können, empfiehlt sich sowohl ein Blick in die Vergangenheit zu den Anfängen der Forschung, als auch auf aktuelle Gegenstände. Dieses Kapitel behandelt die aktuellen Entwicklungen sowie die zu untersuchende Problemstellung der Eignungsdiagnostik. Die historische Entwicklung der KI befindet sich in Unterabschnitt A.2.1. Die nachfolgenden Ausführungen erfolgen in Anlehnung an das im Oktober 2016 eingereichte Exposé, welches nicht veröffentlicht wurde und der Vorstudie zu dieser Arbeit dient (Johannßen 2016).

1.1. Thematische Einleitung

In diesem einleitenden Abschnitt geht es um den aktuellen Stand der KI-Forschung und die Einsatzgebiete neuer Technologien.

1.1.1. AlphaGo schafft einen technologischen Sprung von 20 Jahren

Als die Künstliche Intelligenz AlphaGo des Unternehmens DeepMind am 09. März 2016 gegen den amtierenden südkoreanischen Go-Profi Lee Sedol antrat, wurde dies von KI-Forschern mit Spannung verfolgt. Zwar besiegte der Supercomputer Deep Blue von IBM bereits 1997 den damals amtierenden Schach-Weltmeister Garri Kasparow (Gibney 2016). Doch weist Schach mit dessen 8×8 Feldern und 10^{43} möglichen Spielzügen im Vergleich zum strategischen Brettspiel Go aus China eine weit geringere Komplexität auf. Das Feld von Go mit 19×19 Feldern ermöglicht circa $2,08 \times 10^{170}$ Spielzüge, wie es der Wissenschaftler Tromp (2016) herausstellt. Nach Schraudolph, Dayan und Sejnowski (1994, vgl. S. 819) überstieg diese enorme Menge möglicher Züge die realistische Berechnbarkeit üblicher Algorithmen auf jedem Supercomputer weltweit, sei es durch Alpha-Beta-Suche, Baumtraversierung oder der heuristischen Suche. KI-Forscher gingen davon aus, dass Go-Profis erst in 20 Jahren besiegt werden könnten. AlphaGo besiegte Sedol. Das bestätigte diesen technologischen Fortschritt um zwei Dekaden.

1.1.2. Maschinelles Lernen als Schlüssel für den Berechnungsengpass

Die Rechenkraft von 93 Peta-*Floating Point Operations Per Second* (FLOPS) auf 10.646.900 Computerkernen (Meuer 2016) des Supercomputers Sunway TaihuLight wäre mit üblichen Algorithmen nicht in der Lage, ein Go-Match mit dessen $2,08 \times 10^{170}$ möglichen Zügen ausreichend gut zu berechnen – die Rechenkraft würde nicht ausreichen, um über das Spieler-Niveau eines Kindes hinauszukommen.

Ermöglicht wurde der Sieg gegen Sedol, neben anderen Technologien, durch künstliche neuronale Netze (NN) (Silver u. a. 2016, vgl. S. 484). Bei solchen Computer-Netzen handelt es sich um von der Biologie inspirierte Algorithmen, welche in der Lage sind, deren Topologie auf Basis von Lernalgorithmen zu verändern und so zu neuen Erkenntnissen zu gelangen. Die Idee

von neuronalen Netzen wurde bereits 1943 von den Mathematikern McCulloch und Pitts (1943) formuliert. Auch die Ansätze, neuronale Netzwerke für Computer-Go zu nutzen, sind nicht neu (Miikkulainen 2001). Der innovative Ansatz: AlphaGo spielt gegen sich selbst hunderttausende Partien, mit deren Resultaten das neuronale Netz trainiert wurde (Silver u. a. 2016, vgl. S. 484).

Die Bezwingung des Go-Profis Sedol hat die gewaltige Stärke des durch DeepMind entwickelten Computerprogramms aufgezeigt, war jedoch selbst exemplarischer Natur. Forscher von Künstlichen Intelligenzen erhoffen sich durch den technologischen Zugewinn für die Zukunft sowohl einen Anstieg an Rechenleistung als auch die Erschließung neuer Forschungsfelder und Einsatzgebiete, wie z.B. Predictive Analytics.

1.1.3. Predictive Analytics als Anwendung einer KI

Gemäß Elkan (2013, vgl. S. 25), handelt es sich bei Predictive Analytics um das Schließen auf Zukunftstrends auf Basis der Analyse von Vergangenheitswerten. Dabei soll durch einen Prädiktor, eine Variable aus einer Gesamtmenge, auf zukünftige Sachverhalte und Trends geschlossen werden.

Dafür gibt es viele verschiedene Methoden, darunter auch die Nutzung vom Maschinenlernen. Eine Stärke von Maschinenlertechniken gegenüber herkömmlichen Algorithmen ist die Fähigkeit, nur schwer erkennbare Muster in Datenmengen identifizieren zu können. Anhand von Regeln und Trainingswerten gilt es beim Maschinenlernen, Erfahrungswerte aus Wissen zu generieren. Vorbild für die Computer-Netze sind die Prozesse der Neurobiologie, neuronale Plastizität als Datenspeicher zu nutzen. Technologisch handelt es sich bei Bayes-Netzen und neuronalen Netzen jeweils um gerichtete azyklische Graphen. Die beiden Strukturen unterscheidet, dass neuronale Netze ihre Wahrscheinlichkeitsberechnungen durch die Topologie als Schichten von Knoten realisieren, während Bayessche Netze neben einer Topologie je Knoten so genannte *bedingte Wahrscheinlichkeiten* erlernen.

1.2. Problemstellung und Forschungslücke

Nach Heublein u. a. (2014, vgl. S. 4f.) werden die Abbrecherquoten mathematischer, naturwissenschaftlicher und ingenieurwissenschaftlicher Studiengänge mit bis zu 39%, trotz eines positiven – d.h. rückläufigen – Trends, als weiterhin zu hoch beschrieben. Dieser zugespitzte Fachkräfte- und Expertenmangel kann als Chance verstanden werden, Predictive Analytics

auch auf dem Feld der Studieneignungsdiagnostik anzuwenden und zu evaluieren, ob eine erfolgreichere Auswahl an Studieninteressierten für Studiengänge möglich ist.

In einer Studie von Max C. Wewel, herausgegeben in einem Sammelband von Rentschler und Voss (2008, vgl. S.37ff), kommt Wewel zu dem Ergebnis, dass jene Studierenden ein Studium mit einer höheren Wahrscheinlichkeit erfolgreich abschließen konnten, die eine gute Schulabschlussnote aufwiesen. Unter den Betriebswirtschaftsstudierende mit einer Schulabschlussnote im Intervall von 1,0 bis 1,9 schlossen demnach 77,9% das Studium erfolgreich ab, während lediglich 43,8% der Kommilitonen mit einer Schulabschlussnote zwischen 3,0 und 4,0 das Studium mit einem Abschluss beenden konnten.

Bereits im ersten Artikel empfehlen Sarges und Scheffer (2008, vgl. S. 17), den s.g. *Ego-Involvement* zur Validitätserhöhung stärker zu beachten. Demnach sei mit Ego-Involvement gemeint: „Betroffenheit einer Person durch Relevanz der Stimuli für die eigene Selbstidentität“ (Sherif (1966, vgl. S. 92-116) zitiert in Sarges und Scheffer (2008, S. 17)).

Es zeichnet sich also deutlich ab, dass die Wissenschaft an diesem Punkt uneinig ist. Während einige Wissenschaftler wie Hell, Trapmann und Schuler (2007), sowie Herrmann (2002) der Ansicht sind, Studienauswahltests in Kombination mit Schulleistungen seien sehr gute Prädiktoren für einen Studienerfolg, warnen Sarges und Scheffer (2008) davor, lediglich die intellektuellen Faktoren isoliert zu beachten, was die Analysen nach Schira (2012) bestätigen. Dies stellt die Forschungslücke dieser Arbeit dar, die es zu untersuchen gilt.

1.3. Hypothesenbildung

Durch Predictive Analytics lassen sich Aussagen zu Studienerfolgspotenzialen treffen. Die Forschung der Studieneignungsdiagnostik teilt sich aktuell in zwei Lager: Jene, die einzig die Schulabschlussnote-, und jene, die die Schulabschlussnote in Verbindung mit Ego-Involvement als Wissensbasis für einen guten Indikator halten. Durch eine Wissensbasis lassen sich Expertensysteme, also Systeme, die wie ein menschlicher Experte befragt werden können, erstellen. Wird ein Expertensystem durch ein Bayessches Netz (BN) abgebildet, ist es bei abweichender Datenlage veränderbar. Ferner lassen BNs Aussagen zu Individuen zu. Diese Umstände führen zu folgenden Hypothesen:

Erste Hypothese (h1)

Die Befragung eines Expertensystems anhand von Schulabschlussnoten und Ego-Involvement ergibt bessere Aussagen zum Studieneignungspotenzial als eine isolierte Betrachtung anhand von lediglich den Schulabschlussnoten.

Zweite Hypothese (h2)

Wird ein Expertensystem zu Studieneignungspotenzialen durch ein Bayessches Netz abgebildet, erfüllt es die Zielbestimmungen besser, als es eine statische Betrachtung, wie z.B. mithilfe der uni- oder bivariaten Statistik, zuließe.

Sowohl Predictive Analytics als auch das Maschinlernen und Bayessche Netze lassen sich in eine Vielzahl von darunter befindlichen Methoden und Technologien unterteilen. Sie sind Oberbegriffe für eine Reihe von Lösungsstrategien. So lassen sich Predictive Analytics durch Regressionsanalysen wie die lineare Regression oder Klassifikations- und Regressionsbäumen realisieren. Auch die neuronalen Netze können für Predictive Analytics genutzt werden. Vor allem von Bayesschen Netzen geht, wie eingangs beschrieben, ein hohes Potenzial an Analysefähigkeiten aus. Die jüngsten Ereignisse rund um Googles Forschungen haben auch die Forschung an KI-Netzen vorangetrieben. Aus diesem Grund eignen sich Bayessche Netze als Untersuchungsgegenstand dieser Thesis mehr als z.B. Regressionstechniken.

Daneben gibt Lazer u. a. (2014) an, dass die Diskussion um die Gestalt und den Gewinn von Eignungsdiagnostik auch eine Frage nach der Güte von Big Data-Analysis ist. Diskrete und messbare Faktoren in Big Data werden in Anwendungsgebieten wie dem s.g. Business Intelligence (BI) bereits erfolgreich zum Einsatz gebracht. Der aktuelle Diskurs in der Forschung ist sich jedoch uneins darüber, ob sich hochkomplexe Sachverhalte, wie die Eignungsdiagnostik, überhaupt durch KI-Netze abbilden ließen. Die Verbindung beider Theorien – das Trainieren eines neuronalen Netzes auf Basis von Experteninterviews – stellt somit einen geeigneten Fokus für diese Arbeit dar. Aussagen über die Berechenbarkeit komplexer Sachverhalte durch KI-Netze ist umstritten. Die nicht-kognitive Eignungsdiagnostik ist komplex. Somit ergibt sich für die Verbindung eine hohe wissenschaftliche Relevanz.

Um dem Rahmen dieser Arbeit gerecht zu werden, wird sich bei der Untersuchung auf das Studieneignungspotenzial zukünftiger Softwareentwickler beschränkt. Es geht also um die Frage, wie Studieninteressierte auf die Eignung evaluiert werden können, die notwendige Fähigkeiten zukünftiger Softwareentwickler aufweisen müssen.

1.4. Aufbau und Vorgehen

Die vorgestellten Hypothesen werden in folgenden Abschnitten erarbeitet:

Studieneignungsdiagnostik

Die Studieneignungsdiagnostik weist die erwähnte Forschungslücke auf und bildet die Anwendungsdomäne, wie eingangs erarbeitet. Private Hochschulen wie die Nordakademie durften schon immer eigene Auswahlverfahren einsetzen (Zimmerhofer und Trost 2008, vgl. S. 32). Bei staatlichen Hochschulen ist diese Möglichkeit jedoch neu. Um zu verstehen, warum die Frage nach guten Testverfahren überhaupt aktuell ist, wird im Kapitel 2 zuerst die Öffnung für hochschuleigene Auswahlverfahren im Hochschulgesetz skizziert.

Im Anschluss daran wird ergründet, was die Studieneignungsdiagnostik von der allgemeinen Personaleignungsdiagnostik wirtschaftlicher Unternehmen unterscheidet. Daneben wird sich mit der Frage beschäftigt, wie Erfolg und Misserfolg der Studieneignungsdiagnostik aufgefasst werden können.

Im dritten Teil des Kapitels werden erst allgemeine Eignungsverfahren von Hochschulen skizziert, um anschließend auf den Nordakademie-spezifischen Auswahltest und vor allem dessen Ermittlung besonderer Werte wie dem ViQ, MIX oder IQt einzugehen.

Bayessche Netze

Für viele Expertensysteme sind Bayessche Netze die zugrundeliegende Technologie. Sie basieren auf dem Satz von Bayes und weisen sehr günstige Eigenschaften auf. Um diese ausreichend gut erfassen zu können, beschäftigt sich Kapitel 3 mit den Grundlagen der Bayesschen Netze.

Anfänglich werden einige wenige Grundlagen zur Graphentheorie beschrieben, da ein Bayessesches Netz ein gerichteter azyklischer Graph ist. Entscheidend für den Satz von Bayes sind bedingt abhängige Wahrscheinlichkeiten. Um die Berechnung dieser nachvollziehen zu können, werden Grundlagen der Wahrscheinlichkeitstheorie in Abschnitt 3.2 beschrieben.

Im Anschluss wird das logische Schließen mittels des Bayes-Theorems behandelt. Der bedeutende Satz von Bayes wird in Abschnitt 3.4 beschrieben. Wichtig für die Erstellung des in dieser Arbeit zentralen Expertensystems ist das grundlegende Verständnis von zwei ausgewählten Lernalgorithmen zur Ermittlung der Struktur und der Wahrscheinlichkeitstabellen

eines Bayesschen Netzes. Diese beiden Lernalgorithmen werden zuletzt in Abschnitt 3.5 skizziert.

Entwicklung eines Expertensystems

Wie der Titel dieser Untersuchung angibt, wird es bei der Erstellung und Untersuchung des Expertensystems die Einschränkung geben, dass sich einzig auf das Studieneignungspotenzial zukünftiger Softwareentwickler bezogen wird, um dem Rahmen einer solchen Arbeit gerecht zu werden. Dafür werden die Studieninhalte der Studierenden zur Auswahl geeigneter Module als Indikatoren herangezogen, die in Experteninterviews besprochen und für das System genutzt werden.

Für die Erarbeitung des Expertensystems wird in Kapitel 4 anfänglich die zugrundeliegende Datenbasis – Rohdaten des Auswahlverfahrens der Hochschule – statistisch untersucht, um bereits ein Verständnis für die Datenlage und die Zusammenhänge zu erlangen. Daraufhin wird ein Modell eines Bayessches Netz erstellt, dessen Details anschließend mit Experten in den Experteninterviews besprochen werden. Die Erkenntnisse daraus fließen sowohl in die Datenaufbereitung, als auch in die zu erwartende Umgestaltung des Bayesschen Netzes ein.

Empirische Erprobung und Ergebnisanalyse

Nach der Erstellung des Expertensystems, erfolgt in Kapitel 5 dessen Erprobung. Dafür werden von der Gesamtheit der Datenbasis einige Datensätze ausgewählt. Diese Datensätze sind Repräsentanten einiger Kombinationsklassen. Durch sie wird untersucht, inwiefern die bloße uni- und bivariate Statistik die letztlichen Ergebnisse von für Softwareentwickler relevanten Module hätten bestimmen können und wie das Bayessche Netz im Vergleich dazu abschneidet.

Kritische Eignungsdiskussion und Handlungsempfehlung

Nach der praktischen Erprobung wird in Kapitel 6 eine allgemeine Handlungsempfehlung für gleichartige Probleme abgeleitet. Dazu wird ferner die Güte dieses Ansatzes speziell für diesen angewendeten Fall bewertet.

2. Studieneignungsdiagnostik

Um das theoretische Fundament für die weiteren Untersuchungen zu schaffen, behandelt dieses Kapitel, nach einer Skizzierung des Paradigmenwechsels bis zur Moderne, zuerst die Eignungsdiagnostik generell und die Studieneignungsdiagnostik als Spezialgebiet. Ferner werden einige Ansätze zur Definition von Erfolg und Misserfolg geschildert.

2.1. Öffnung für hochschuleigene Auswahlverfahren im Hochschulgesetz

Nicht nur die Arbeitspsychologie selbst hat in den vergangenen Jahren und Jahrzehnten einen Paradigmenwechsel erlebt, wie er im Anhang unter Unterabschnitt A.2.2 beschrieben wird. Auch die rechtlichen Vorgaben an die Studierendenauswahl gemäß Deutschem Hochschulgesetz hat sich dem liberaleren Trend angepasst. Diese Entwicklung wurde von Zimmerhofer und Trost (2008, vgl. S. 32ff.) folgendermaßen zusammengefasst:

Direkt nach dem Zweiten Weltkrieg lag der Fokus auf dem Wiederaufbau des Hochschulsystems. Die allgemeine Hochschulzulassung wurde von den Hochschulen selbst ausgewertet und stellenweise wurden Motivationsinterviews geführt. Bis in die 1960er Jahre stieg die Anzahl an hochschuleigenen Auswahlverfahren stark an. Häufig wurden individuelle Fächerkombinationen betrachtet. Vor allem die medizinischen Fakultäten beschlossen der Heterogenität der Auswahlverfahren mit einem vereinheitlichten Verfahren zu begegnen. Ab 1967 wurde eine Dienstleistungsstelle zur zentralen Vergabe von Studienplätzen eingeführt, die fortan die Hochschulbewerbungen entgegennahm. Davor gingen Bewerbungen bei den Hochschulen selbst ein. Aufnahmekriterien blieben dennoch weiterhin hochschulspezifisch.

Das *Numerus-clausus-Urteil* von 1972 ebnete den Weg für das auch noch heute vielgenutzte Recht der freien Berufswahl in Deutschland. Dieses Recht wurde auf die staatlichen Hochschulen ausgeweitet und gilt somit nicht für private Institutionen wie die Fachhochschule (FH) Nordakademie (NAK). Eine einheitlich berechnete Durchschnittsnote aus der Hoch-

schulzulassung entscheidet über eine Studienplatzvergabe, wenn die Anzahl der Bewerber die verfügbaren Studienplätze überschreitet. Ein s.g. *Bonus malus*, regional besser vergebene Durchschnittsnoten, wird zur Vergleichbarkeit aller Länder herausgerechnet.

Ein weiteres *Numerus-clausus-Urteil* wurde 1977 erlassen, wonach bei Studiengängen mit erheblichem Bewerberandrang ein alternatives, beschleunigtes Auswahlverfahren eingesetzt werden durfte. Dabei mussten Zulassungsberechtigte auch weiterhin die Chance auf einen Studienplatz haben. 1986 wurde für die medizinischen Studiengänge ein zentrales Auswahlverfahren, der *Test für medizinische Studiengänge* (TMS), eingeführt und wird auch heute noch eingesetzt. 60% der Studienplätze zulassungsbeschränkter Studiengänge dürfen gemäß dem Hochschulrahmengesetz heutzutage nach den Kriterien der Hochschule vergeben werden. Dies war eine Reaktion der Politik auf die Forderung der Hochschulen, stärkeren Einfluss auf die Studienplatzvergabe nehmen zu dürfen.

Es lässt sich also feststellen, dass eine Liberalisierung der Eignungsverfahren stattgefunden hat. Somit werden auch Eignungsverfahren wie einem Expertensystem auf Basis eines Bayesschen Netzes zur Studieneignungsdiagnostik immer wichtiger.

2.2. Abgrenzung zur Eignungsdiagnostik des Personalwesens

Die Studieneignungsdiagnostik ist ein Teilgebiet der allgemeinen Eignungsdiagnostik, der auch die Personaleignungsdiagnostik angehört. Es gibt daher Parallelen zur Personalbeschaffung eines wirtschaftlichen Unternehmens. Schuler und Hell (2008, vgl. S. 15f.) stellen in Frage, inwieweit die eignungsdiagnostischen Prinzipien auf den Hochschulbereich übertragen werden können.

Demnach unterscheiden sich in den beiden Bereichen sowohl die grundlegenden Ziele der Eignungsdiagnostik als auch das Verständnis der einzustufenden Personen. Ein wirtschaftliches Unternehmen hat das Bestreben, die optimalen Bewerber für eine Stelle auszuwählen. Eine Hochschule möchte hingegen lediglich vermeiden, zukünftige Studienabbrecher auszuwählen. Eine Hochschule möchte keine geeigneten Anwärter ablehnen. Die Besten zu finden ist hingegen nicht das Ziel.

Daneben ist auch das Verständnis von Studierenden als „Kunden“ gemäß einem wirtschaftlichen Unternehmen nicht stimmig. So würde ein Unternehmen seine Kundschaft nicht durch Klausuren prüfen oder diese bei Misserfolg exmatrikulieren. Vielmehr würde es die Wünsche der Kundschaft ins Zentrum der Bemühungen gemäß der Marketingwissenschaft rücken.

Einen Sonderfall stellt ein gemischtes Konzept dar, wie es auch für die FH Nordakademie der Fall ist. Studierende absolvieren vor der Bewerbung bei einem Unternehmen hochschuleigene Auswahltests. Sind diese mindestens bestanden worden, bewirbt sich ein Studieninteressierter bei Unternehmen und durchläuft den unternehmensinternen Auswahlprozess. Diese Mischform ermöglicht der Hochschule, Studienabbrecher frühzeitig zu identifizieren, um das Studienziel für alle Studierenden zu gewährleisten. Die auswählenden Unternehmen hingegen verfolgen im Zweifel das Ziel, diejenigen auszuwählen, welche die besten Studienergebnisse erzielen oder besonders gut zum Unternehmen passen.

2.3. Verständnis von Erfolg und Misserfolg in der Studieneignungsdiagnostik

Bevor Maßnahmen der Studieneignungsdiagnostik ergriffen werden können, muss geklärt sein, wie *Studienerfolg* zu verstehen ist.

Zimmermann umschreibt „Erfolg“ damit, dass Erfolg habe, wer ankomme (Schmidt 2010). Dabei differenziert der Informatik-Professor der FH Nordakademie deutlich, dass es auf die berufliche Perspektive ankomme. Damit sind die beiden unterschiedlichen Auffassungen von *Studienerfolg* benannt: Viele Hochschulen verstehen den Studienerfolg als erfolgreichen Abschluss eines Studiums und damit als Graduierung. Andere Hochschulen und vor allem wirtschaftlich orientierte Institutionen begreifen den Studienerfolg darüber hinaus als Studienabschluss mit mindestens durchschnittlichen Ergebnissen oder gezeigter Berufsqualifizierung.

Auch Hell, Trapmann und Schuler (2008, vgl. S. 44f) benennen den Abschluss des Hochschullexams als Erfolg. Ansätze können jedoch auch eine geringe Anzahl an Prüfungswiederholungen, eine geringe Studiendauer oder überdurchschnittliche Examens- oder Einzelmodulnoten sein. Die Studieninteressierten der Nordakademie durchlaufen mehrere Auswahlprozeduren, deren Zielsetzung sich unterscheidet. Da nach Hell, Trapmann und Schuler (ebd.) das generelle Verständnis von Studienerfolg der Hochschulen die Graduierung ist, dürfte die FH Nordakademie selbst das Interesse verfolgen, lediglich potenzielle Abbrecher zu identifizieren. Die

Unternehmen, welche die Dualstudierenden selektieren und ihnen damit einen Studienplatz ermöglichen, verfolgen mutmaßlich einen eher leistungsorientierten Ansatz. Dabei definieren diese generell eigene Auswahlverfahren und Auswahlziele.

2.4. Gängige eignungsdiagnostische Verfahren

Es gibt zahlreiche Untersuchungen zu der Frage, ob Schulnoten die besten Leistungsindikatoren sind. Fast einvernehmlich wird festgestellt, dass andere Indikatoren die Aussage beeinflussen können. Doch insgesamt sind schulische Noten die besten Indikatoren für spätere Studienerfolge. So ermittelten Hell, Trapmann und Schuler (2008, vgl. S. 46) eine Validität des Rangkorrelationskoeffizienten der schulischen Noten von $\rho = 0,517$. Ferner wurde positiv herausgestellt, dass Noten, welche über mehrere Jahre durch Beobachtung und Prüfungen erstellt wurden, ein besseres Bild über die tatsächliche Leistungserbringung junger Studienanwärter ermöglichen, als es kurzfristige Testverfahren, wie z.B. Assessment Center (AC), bewerkstelligen könnten. Dazu ist der Vergleich mit dem Hawthorne-Versuch in Unterunterabschnitt A.2.2.4 angemerkt, bei dem Probandinnen durch Beobachtungen bessere Ergebnisse erzielten, um als Individuum in der Gruppe als tüchtiger wahrgenommen zu werden. Der zusätzliche Einsatz von Auswahlgesprächen zu den schulischen Noten konnte nach Hell, Trapmann und Schuler (ebd., vgl. S. 50) die Validität auf $\rho = 0,522$ geringfügig steigern. Gleichsam kommen die Autoren jedoch zu dem Schluss, dass Interviews durch die geringe Validität von $\rho = 0,205$ im Grunde irrelevant sind und somit der Erkenntnisgewinn in keinem Verhältnis zu dem hohen Aufwand dafür steht.

Hell, Trapmann und Schuler (2007, vgl. S. 11ff.) weisen zudem auf den ökonomischen Nutzen von Noten als alleinige Indikatoren hin. Die gute Studieneignungsdiagnostik durch Noten reduziert demnach die volkswirtschaftlichen Kosten einer fehlerhaften Auslese im Vergleich zu anderen Auswahlverfahren. Eine gute Auslese der Studieninteressierten, also das Verhindern von Studienabbrüchen, würde eine höhere Zufriedenheit der Studierenden, geringere Kosten durch Folgeausbildungen und Einsparungen durch kurze Studienzeiten bedeuten. Ferner sind andere Auswahlverfahren weit kostspieliger als die bloße Betrachtung von schulischen Noten. Auswahlgespräche müssen durch eine Anforderungsanalyse und eine Konzeptionsphase erstellt werden. Die Interviewer müssen trainiert werden und auch die Auswahlgespräche selber dauern lange in ihrer Durchführung und Auswertung. Somit sind schulische Noten auch ökonomisch die günstigsten Leistungsindikatoren.

Neben den sehr positiven Studien zur Güte von Noten gibt es auch Kritik an dieser Herangehensweise. Scheffer (2016) stellt heraus, dass die spätere berufliche Performance in keinem Zusammenhang mit den schulischen Noten stehe. Es zeigte sich demnach gar, dass stellenweise bessere Schulnoten mit schlechteren Resultaten in ACs einhergingen (vice versa). Auch Hell, Trapmann und Schuler (2007, S. 13) kritisieren an schulischen Noten, dass der Informationsgehalt von Beobachtungen an die Methode der Messung gebunden sei und damit mehr Datenquellen als nur eine schulische Institution weit bessere Aussagen über die tatsächliche Leistung zuließen. Ferner wird zudem die Vergleichbarkeit von Reifezeugnissen unterschiedlicher Bundesländer angezweifelt. So untersuchte Schleithoff (2015, vgl. S. 6) die Notenentwicklung unterschiedlicher Bundesländer, um der Frage auf den Grund zu gehen, ob eine *Noteninflation* der Hochschulreifezeugnisse stattfindet. Dabei wurde ersichtlich, dass es gravierende Unterschiede zwischen den Bundesländern gibt. Thüringen vergab im Mittel eine Note von 2,17 an Absolventen, während Baden-Württemberg im Durchschnitt eine 2,46 vergab. Beide Absolventengruppen werden trotz der augenscheinlich unterschiedlichen Bewertungsmaßstäbe gleichsam nach der Abschlussnote bewertet.

2.5. Nordakademie-Auswahltest

Neben schulischen Noten kann es eine große Zahl an möglichen eignungsdiagnostischen Parametern geben. Für diese Arbeit besonders relevant ist dabei die Frage, welche Parameter für die Studierenden der Nordakademie erfasst werden, und vor allem, wie diese zu interpretieren sind. Ohne das fachliche Hintergrundwissen zu den Parametern ist eine sinnvolle Erstellung und Befragung eines Expertensystems nicht denkbar. Daher behandelt dieser Abschnitt die eignungsdiagnostischen Parameter des Auswahltests der FH Nordakademie, um den fachlichen Hintergrund aufzubauen.

2.5.1. Englisch-, Mathe- und Wissenstest der FH Nordakademie

Der Englischtest der FH Nordakademie gliedert sich in zwei Teile: Fragen zur englischen Grammatik und Textverständnis der englischen Sprache. Die Bewerber lesen im ersten Teil erst einen Text und beantworten anschließend Fragen zum Verständnis.

Der Mathematiktest umfasst insgesamt zehn Fragen, die Grundwissen aus der Fachhochschulreife abfragen. Darunter sind Dreisatz-Aufgaben, Prozentrechnung oder Bruchrechnung. Das

Niveau wurde absichtlich auf einfache Inhalte der Hochschulreife beschränkt. Dies hat vor allem den Grund, dass nur potenzielle Studienabbrecher gefiltert, nicht aber die besten Kandidaten ausfindig gemacht werden sollen (vgl. dazu Abschnitt 2.2).

Auch der vorgesehene Wissenstest zum jeweiligen Fachgebiet des Studiums beschränkt sich auf einfache Grundlagen und hat nicht das Ziel, besonders versiertes Vorwissen zu honorieren.

2.5.2. MIX

Nach Sarges und Scheffer (2008) handelt es sich bei den MIX-Motiven um Wollensfaktoren, die für jeden Menschen unterschiedlich ausfallen. Manche seien demnach konsistent und stabil erhöht gegenüber anderen. Die Begründung der unterschiedlichen Niveaus liegt der Vermutung nach in der unterschiedlichen Lerngeschichte eines jeden Probanden.

Im Auswahltest der FH Nordakademie werden die MIX-Motive durch die Darstellung von unscharfen Bildern gewonnen. Als Freitext sind Fragen zur Interpretation dargestellter Personen zu beantworten, wie z.B. wer die vermutliche Hauptperson ist und was diese empfindet. Ein solches Beispiel ist in Abbildung 1 dargestellt.

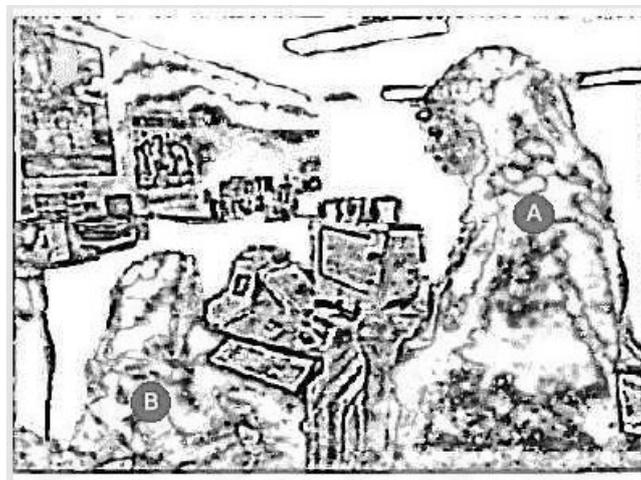


Abbildung 1.: Frage aus dem MIX-Katalog, entnommen dem Nordakademie-Auswahltest.
Quelle: Sarges und Scheffer (2008). Erlaubnis der Benutzung mit Genehmigung von Prof. Dr. David Scheffer (Januar 2017).

Die Grobuntergliederung der einzelnen MIX-Motive erfolgt in *Bindung*, *Leistung* und *Macht*:

Bindung:

Probanden mit einem starken Bindungs-Motiv streben nach Harmonie. Sie suchen gesellschaftlichen Zusammenhalt und vermeiden Konflikts- oder Wettbewerbssituationen.

Leistung:

Ein starkes Leistungs-Motiv bedeutet ein Exzellenzstreben. Die Leistungsziele von Probanden sind hoch gesteckt, aber zumeist erreichbar. Gelegentlich behindert das Streben nach Perfektion und Leistung das soziale Gefüge von stark Leistungsmotivierten.

Macht:

Im Englischen wird Macht im Motiv-Sinne mit „power“ übersetzt. Probanden mit einem hohen Macht-Motiv haben das Bestreben, etwas zu bewirken oder gegebene Umstände zu beeinflussen und zu verändern. Dafür sind sie leistungsbereit. Sofern auch das Leistungs-Motiv ausgeprägt ist, wird das Macht-Motiv bedient. Andernfalls kann ein starkes Macht-Motiv in Frustration münden.

2.5.3. ViQ

Der Visual Questionnaire (ViQ) nach Scheffer u. a. (2016) und Scheffer und Loerwald (2008) ist ein vor allem visuell erfasster Indikator. Probanden des Auswahltests der FH Nordakademie werden vor die Wahl zwischen zwei Motiven gestellt. Sie entscheiden dabei lediglich, welche Form ihnen mehr zusagt. Davon ableiten lassen sich nach Scheffer und Loerwald (ebd., vgl. S. 54) unterschiedliche Dimensionen der Persönlichkeit. Ein Beispiel für das Testverfahren findet sich in Abbildung 2. Nachfolgend werden die für diese Arbeit relevanten Dimensionen knapp erläutert.



Abbildung 2.: Frage aus dem ViQ-Katalog, entnommen dem Nordakademie-Auswahltest. Quelle: Sarges und Scheffer (2008). Erlaubnis der Benutzung mit Genehmigung von Prof. Dr. David Scheffer (Januar 2017).

ViQ-s (Sensing): Diese Dimension führt zu einer quantitativen, fragmentierten Wahrnehmung. Einfachheit wird einem hohen Detailgrad vorgezogen. Stimuli der Überraschung oder Komplexität werden vermieden. Vor allem wenn Abstraktion von Nöten ist, kann diese Dimension Vorteile erbringen.

ViQ-n (Intuition): Die Intuition-Dimension führt zu einer schnellen Aufnahme von komplexen Stimuli. Automatische Körper-Prozesse und teilweise unbewusste Vorgänge werden umgangen. Es kommt zu präzisen Interpretationen bei minimalen Informationen. Somit sorgt diese Dimension für ein enorm rasches Adaptieren hochkomplexer Sachverhalte und Umgebungen.

ViQ-t (Thinking): Schnelle Erfassung von systematischer oder logischer Ordnung wird durch die ViQ-t-Dimension bestimmt. Damit ist vor allem die Frage nach Wahrheit und Unwahrheit als Antwortmöglichkeiten gemeint. Vorausschauendes Denken und Planen sind Stärken.

ViQ-f (Feeling): Ganzheitliche und emotionale Betrachtungsweisen äußern sich in der ViQ-f-Dimension. Ein starkes Interesse an der sozialen Umwelt und am sozialen Gefüge sind das Resultat. Vor allem besonders große Mengen an Informationen und Eindrücken können mit einer starken ViQ-f-Dimension besonders effizient verarbeitet werden – häufig gar parallel.

ViQ-e (Extraversion): Ein hoher Wert der ViQ-e-Dimension ist vor allem ein Indikator dafür, dass ein Proband Sensationen sucht. Dazu kommen vor allem Toleranz, aber auch Vieldeutigkeit. Entscheidungen werden oft danach gefällt, welche Außenwirkungen diese für den Probanden hätten.

ViQ-j (Judging): Eindeutige Entscheidungen, Sicherheit, Norm-Orientiertheit und die Vermeidung von Unklarheiten sind der Fokus von Menschen mit starker ViQ-j-Dimension. Vor allem unklare Design-Elemente irritieren derartige Menschen.

2.5.4. IQt

Der Technische Intelligenz-Quotienten (IQt) wird durch einen klassischen Intelligenztest mit Auswahl von mathematisch-technischen IQ-Untersuchungen ermittelt. Untersucht werden dabei die Bereiche Sprache, Merkfähigkeit, Logik, Rechnen und Technik. Erfasst werden die IQt-Werte als prozentuale Anteile der Probanden, die schlechter als der Prüfling abgeschnitten haben in ganzzahligen Prozentzahl (Plate 2016a).

Das Sprachverständnis wird unter Anderem durch Wort-Permutationen geprüft. Es wird dem

Probanden z.B. die Frage gestellt, welches von vier nachfolgenden Wörtern einem Vogel entspricht (SELMA für Amsel). Weitere Fragen geben ein Sprichwort vor, zu dem ein weiteres, gleichbedeutendes Sprichwort aus einer Auswahl von Vieren gewählt werden muss.

Zum Technikverständnis wird dem Probanden z.B. eine Auswahl an andersartig geformten Stahlträgern präsentiert, von denen sie den stabilsten auswählen sollen. Auch Zahnrad-Konstellationen und die Frage danach, welches System sich korrekt drehen könnte, sind Bestandteil des IQT-Technik-Wertes. Ein weiteres Beispiel dafür ist dargestellt in Abbildung 3.

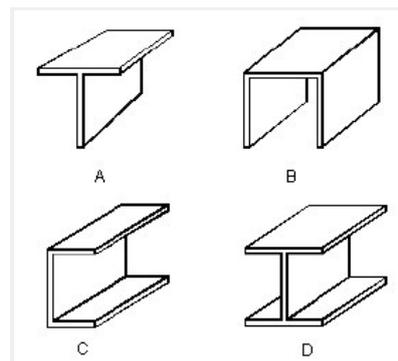


Abbildung 3.: Frage aus dem IQT-Katalog, entnommen dem Nordakademie-Auswahltest. Quelle: Sarges und Scheffer (2008). Erlaubnis der Benutzung mit Genehmigung von Prof. Dr. David Scheffer (Januar 2017).

Zur Prüfung des IQT-Rechnen-Werts werden simple Rechenaufgaben herangezogen, die ohne Hilfsmittel in kurzer Zeit korrekt gelöst werden sollen. Dabei ist vor allem die zeitliche Begrenzung auf wenige Sekunden die Herausforderung.

Logisches Verständnis wird unter Anderem durch die Fortführung von Zahlenreihen geprüft. Dabei ist die Herausforderung, besonders rasch Schemata zu erkennen und sie auf die Zahlenreihe weiter anzuwenden. Auch die logische Weiterführung von Grafiken und Symbolen wird auf diese Weise abgeprüft.

Die Merkfähigkeit der Probanden wird abgeprüft, indem beispielsweise eine ausführliche Adresse einer Person für wenige Sekunden aufgezeigt und wieder verdeckt wird, wonach Detailfragen z.B. zur Hausnummer oder Postleitzahl gestellt werden. Auch Wortfelder werden auf diese Weise kurzzeitig dargestellt, um anschließend zu fragen, welcher Buchstabe nicht vorkam.

3. Bayessche Netze

Das Forschungsfeld der Künstlichen Intelligenz ist äußerst breit gefächert. Es umfasst unter anderem logische Agenten, Planen, probabilistisches Schließen, Suchverfahren oder Inferenzen. Für diese Arbeit relevant sind jedoch einzig Bayessche Netze (BN) und damit die Graphentheorie, die Wahrscheinlichkeitslehre, der Satz von Bayes und die Grundlagen des probabilistischen Schließens. Diese Gebiete werden in ihren Grundzügen in diesem Abschnitt grob skizziert.

3.1. Graphentheorie

Ein Graph ist eine Datenstruktur, die aus *Ecken* und *Kanten* besteht. Definiert wird sie folgendermaßen:

„Ein *Graph* $G = (V, E)$ besteht aus einer [...] Menge $V = \{v_1, v_2, \dots, v_m\}$ von Ecken [...] und einer [...] Menge $E = \{e_1, e_2, \dots, e_n\}$ von Kanten [...]“ (Owsnicki-Klewe 2002, S. 38).

Bei einem Bayesschen Netz handelt es sich nicht um ein neuronales Netz, wie es der Name vermuten lässt. Bei einem neuronalen Netz liegt zwar ebenfalls ein gerichteter Graph vor, doch jeder Verknüpfung in einem Neuronalen Netz ist ein numerisches Gewicht zugeordnet, das Stärke und Vorzeichen festlegt (Russell und Norvig 2012, vgl. S. 843f.). Stattdessen handelt es sich bei einem Bayesschen Netz um einen gerichteten azyklischen Graphen (engl. directed acyclic graph (DAG)) mit gesonderten Informationen je Knoten in Form von Wahrscheinlichkeitstabellen (CPTs). Ein DAG ist dargestellt in Abbildung 4. Um der Anforderung eines ungerichteten Graphen gerecht zu werden, muss folgende Eigenschaft erfüllt sein:

$$\{\exists \text{ ein Pfad von } v_i \text{ zu } v_j\} \Rightarrow \{v_i \prec v_j\}$$

Diese Eigenschaft besagt, dass es keine gerichtete Kante von v_i zu v_j geben darf, wenn der Knoten v_i der Vorgänger von v_j ist. Ein Knoten ohne Vorgänger in einem DAG wird Wurzel

genannt. Knoten ohne Nachfolger in einem DAG werden Blätter genannt. Alle Knoten, die in der Sequenz von v_i zu v_j liegen, werden *Vorgänger* von v_j genannt. Gibt es genau eine gerichtete Kante von v_i zu v_j , wird v_i *parent* von v_j genannt, während v_j als *child* von v_i bezeichnet wird (Scutari und Denis 2014, vgl. S. 175).

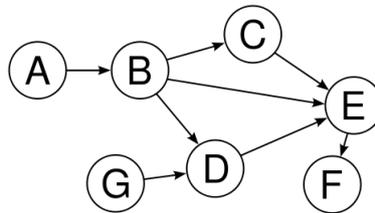


Abbildung 4.: Gerichteter azyklischer Graph (DAG). Quelle: W. (2017)

3.2. Wahrscheinlichkeitstheorie und bedingte Wahrscheinlichkeiten

Häufig ist es nicht möglich, alle Kausalitäten und Einflussfaktoren zu beobachten oder zu berechnen, die für eine Entscheidung von Relevanz sind. Um dennoch qualifizierte Entscheidungen oder Aussagen treffen zu können, wird mit Unsicherheiten quantifiziert. Von zentraler Bedeutung dafür sind Wahrscheinlichkeiten. Nach Russell und Norvig (2012, S. 570) bietet „die Wahrscheinlichkeit eine Möglichkeit, die Unsicherheit zusammenzufassen, die aus [einer Evidenz] und Unwissen“ entsteht. Grundlegend ist eine Wahrscheinlichkeit die Menge der Welten, für die die probabilistische Behauptung wahr sind. Eine Wahrscheinlichkeit bewegt sich dabei stets im Intervall $[0, 1]$. Ein Wahrscheinlichkeitsmodell weist jeder Welt eine Wahrscheinlichkeit zu. Die Gesamtwahrscheinlichkeit aller Welten ist dabei stets 1 (ebd., S. 573), sodass gilt:

$$0 \leq P(\omega) \leq 1 \quad \text{für jedes } \omega \quad \text{und} \quad \sum \omega \in \Omega$$

Die Wahrscheinlichkeit für eine probabilistische Behauptung ist die Summe der Wahrscheinlichkeiten aller Welten, für die die Behauptung wahr ist, sodass gilt:

$$\text{Für jede Aussage } \phi \text{ ist } P(\phi) = \sum \omega \in \phi P(\omega).$$

Für den Satz von Bayes und somit Bayessche Netze bedeutsam sind nicht *A-priori-Wahrscheinlichkeiten*, bei denen für die Glaubensgrade einer Aussage keine weiteren Informationen vorhanden sind, so wie bei Würfeln, sondern *A-posteriori-* oder *bedingte Wahrscheinlichkeiten*. Russell und Norvig (2012, S- 573) nutzen zur Veranschaulichung Würfelwürfe. So kann ein Wurf mit zwei Würfeln zur selben Zeit als unbedingte Wahrscheinlichkeit angesehen werden, da nur die Informationen aus ebendiesem Wurf für einen Glaubensgrad von Relevanz sind. So berechnet sich die Wahrscheinlichkeit für das Würfeln der Augenzahl 11 als:

$$P(\text{Gesamt} = 11) = P((5,6) + P(6,5) = 1/36 + 1/36) = 1/18$$

Es müssen bei dem (unbedingt wahrscheinlichen) Wurf zweier Würfel mit der Augenzahl 11 die zwei Fälle betrachtet werden, dass der erste Würfel eine 5, der zweite eine 6 anzeigt und vice versa. Da jeder Würfel 6 mögliche Werte annehmen kann, berechnet sich die Wahrscheinlichkeit somit als $1/6 * 1/6 = 1/36$. Diese beiden Welten zusammengenommen ergeben dann die unbedingte Wahrscheinlichkeit für die Augenzahl 11 bei dem Wurf zweier Würfel.

Bedingte Wahrscheinlichkeiten lassen sich ebenfalls gut mit Würfeln veranschaulichen. So liegt eine bedingte Wahrscheinlichkeit vor, wenn erneut die Augenzahl 11 durch zwei Würfel erzielt werden soll, wobei der erste Wurf bereits mit einem Würfel erfolgt ist und dieser die Augenzahl 5 aufzeigt. Somit ist die Frage, wie hoch die Wahrscheinlichkeit dafür ist, mit dem zweiten Würfel die Gesamtzahl 11 zu würfeln, wenn bereits eine 5 gewürfelt wurde. Die Aussage ist nun also *bedingt* durch eine Information. Notiert wird dieses durch $P(a|b)$ und gelesen als: „Die Wahrscheinlichkeit für b unter der Voraussetzung von a“. Der Glaubensgrad einer solchen Aussage ist dann so zu verstehen, dass wenn $P(a|b) = 0,5$ ist, die Wahrscheinlichkeit für b genau dann zu einer Wahrscheinlichkeit von 0,5 wahr ist, wenn a eingetreten ist und es keine weiteren Informationen dazu gibt. Definiert wird eine bedingte Wahrscheinlichkeit wie folgt:

$$P(a|b) = \frac{a \wedge b}{P(b)}$$

Hierauf lässt sich die Produktregel anwenden als $P(a \wedge b) = P(a|b)P(b)$ sowie die Inklusion und Exklusion mit $P(a \vee b) = P(a) + P(b) - P(a \wedge b)$.

3.3. Inferenzen

So genannte gemeinsame Verteilungen sind nach Russell und Norvig (2012, vgl. S. 580) eine gängige und einfache Methode, um probabilistische Inferenzen bzw. A-priori-Wahrscheinlichkeiten zu berechnen. Es wird dafür eine Tabelle konstruiert, die alle möglichen Welten beinhaltet und deren einzelne Ereignisse in Verteilungen eingetragen werden. Ein Beispiel ist dargestellt in Tabelle 1. In dem Beispiel einer $2 \times 2 \times 2$ Tabelle werden drei boolesche Variablen aufgeführt: Das Verspüren von Zahnschmerzen, das Vorhandensein eines Zahnlochs und das Verfangen eines ärztlichen Instruments sowie ihre Negierungen (\neg). Die Wahrscheinlichkeiten einer booleschen Variable (negiert und nicht-negiert) ergeben in Summe per Wahrscheinlichkeitsaxiom stets 1.

An solchen vollständigen gemeinsamen Wahrscheinlichkeiten in Tabellenform lassen sich bedingte und unbedingte Wahrscheinlichkeiten mithilfe der Formeln aus Abschnitt 3.2 leicht ablesen. Ist aus Tabelle 1 gefragt, wie hoch die Wahrscheinlichkeit für $P(\text{loch})$ ist, so muss die unbedingte Wahrscheinlichkeit für jede Welt addiert werden, in der diese Behauptung stimmt: $P(\text{loch}) = 0,108 + 0,012 + 0,072 + 0,008 = 0,2$. Damit ergibt sich durch die Exklusivität auch gleich die Wahrscheinlichkeit für $P(\neg\text{loch}) = 1 - P(\text{loch}) = 0,8$.

Bedingte Wahrscheinlichkeiten folgen den Formeln aus Abschnitt 3.2. Wird die Wahrscheinlichkeit von einem Loch unter der Voraussetzung von vorhandenen Zahnschmerzen gesucht, so berechnet sich dies wie folgt:

$$\begin{aligned}
 P(\text{loch}|\text{zahnschmerzen}) &= \frac{P(\text{loch} \wedge \text{zahnschmerzen})}{P(\text{zahnschmerzen})} \\
 &= \frac{0,108 + 0,012}{0,107 + 0,012 + 0,016 + 0,064} = 0,6
 \end{aligned}$$

	zahnschmerzen		\neg zahnschmerzen	
	verfangen	\neg verfangen	verfangen	\neg verfangen
loch	0,108	0,012	0,072	0,008
\neg loch	0,016	0,064	0,144	0,576

Tabelle 1.: Beispiel einer Tabelle mit vollständiger gemeinsamer Verteilung

3.4. Satz von Bayes

Durch die bereits in Abschnitt 3.2 erwähnte Produktregel, konnte der Mathematiker Thomas Bayes bereits 1763 in seinem Werk *An Essay towards solving a Problem in the Doctrine of Chances* den nach ihm benannten *Satz von Bayes* aufstellen (Price 2013, Nachdruck von 1763. Vgl. S. 23). Die Produktregel für bedingte Wahrscheinlichkeiten lässt sich auf zweierlei Weise ausdrücken:

$$P(a \wedge b) = P(a|b)P(b) \quad \text{und} \quad P(a \wedge b) = P(b|a)P(a)$$

Werden diese Gleichungen rechts gleichgesetzt und durch $P(a)$ dividiert, so erhält man nach Russell und Norvig (2012, S. 585) den Satz von Bayes:

$$P(A | B) = \frac{P(B | A)P(A)}{P(B)}$$

Die Konsequenz dieser Regel ist, dass sich der Term $P(b|a)$ durch $P(a|b)$, $P(b)$ und $P(a)$ berechnen lässt. In der Praxis erhält man als Indiz einen Effekt einer unbekannteren Ursache. In diesen Fällen lässt sich der Satz von Bayes nutzen, um mithilfe der drei häufig bekannten Terme den vierten, unbekannteren Term zu errechnen:

$$P(\text{ursache}|\text{effekt}) = \frac{P(\text{effekt}|\text{ursache})P(\text{ursache})}{P(\text{effekt})}$$

Die Verknüpfungen eines Bayesschen Netzes legen fest, welche Variablen von welchen anderen Variablen abhängig sind. Wie bereits in Abschnitt 3.1 beschrieben, sind Vorgänger eines Knotens (in diesem Fall also einer Variable) all jene Knoten, die über eine Kantenfolge verbunden sind. All diese Vorgängerknoten bedingen eine Variable – diese Variable ist also bedingt abhängig von allen Vorgängerknoten, weshalb die Ausprägung dieser Variable somit zur Menge der *Ursachen* gehört. Die Rechnung erfolgt, einfach betrachtet, den Regeln der Wahrscheinlichkeitstheorie. Diese ist jedoch wenig intuitiv und erfolgt mit weiteren algebraischen Methoden, wie der Produktregel. Eine beispielhafte Rechnung ist zum besseren Verständnis in Abschnitt A.6 aufgeführt.

In der Realität sind Bayessche Netze eines solch geringen Umfangs wie im Beispiel aus dem Anhang oder in dieser Arbeit in Abschnitt 4.6 wenig sinnvoll. Stattdessen werden Bayessche

Netze in der Praxis häufig durch maschinelles Lernen anhand entsprechender Algorithmen erstellt und nehmen einen weit größeren Umfang ein. Solch ein Beispiel der Wissenschaftler Yan u. a. (2010) ist dargestellt in Abbildung 5.

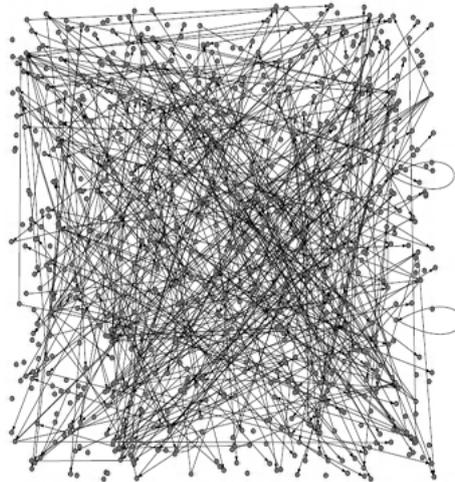


Abbildung 5.: Bayessches Netz, wie es in der Realität anzutreffen ist (hier: Aus der Genetik).
Der Umfang übersteigt die Beispielnetze bei weitem. Quelle: Yan u. a. (2010)

Ein Bayessches Netz ist in der Lage, die Wahrscheinlichkeiten bedingter Abhängigkeiten in einem gerichteten azyklischen Graphen besonders kompakt darzustellen. Durch diese Eigenschaften, eine Wissensbasis für Inferenzabfragen nutzen zu können, wurde der Satz von Bayes die Grundlage der meisten Expertensysteme und nimmt damit eine bedeutende Rolle in der Wissenschaft der Künstlichen Intelligenz ein.

3.5. Lernalgorithmen für Struktur und Parameter

Bayessche Netze bieten die Möglichkeit, sowohl Struktur als auch Parameter händisch oder durch Lernalgorithmen zu gestalten bzw. zu ermitteln. Dies berücksichtigt auch Software wie das Paket „bnlearn“ der Programmiersprache R. Unterschieden werden Lernalgorithmen zunächst in das Lernen der Struktur, also der Topologie des DAG, und das Lernen der Parameter, also der Wahrscheinlichkeitsverteilungen.

In der Praxis werden oft beide Methoden eingesetzt. Hier spiegelt sich die Definition des maschinellen Lernens wider. Das Maschinellenlernen sei nach Russell und Norvig (2012, S.

23) die Eigenschaft, „sich an neue Umstände anzupassen, sowie Muster zu erkennen und zu extrapolieren“. Für das Lernen der Parameter und derer abhängigen Wahrscheinlichkeitstabellen (engl. Conditional Probability Table (CPT)) ist es notwendig, bereits die Struktur des DAG erstellt oder gelernt zu haben. Dazu dient die Nummerierung der Schritte. Beide Schritte können durch *unüberwachtes* Lernen anhand entsprechender Lernalgorithmen oder durch *überwachtes* Lernen anhand von Experteninterviews erlernt werden (Scutari und Denis 2014, vgl. S. 95). Für diese Arbeit wird die Methode des *unüberwachten* Lernens der Struktur und des *überwachten* Lernens der Parameter durch Experteninterviews gewählt. Anschließend erfolgt eine ebenfalls unüberwachte algorithmische Ermittlung der Verteilung. In der Praxis ist dieses gemischte Vorgehen aus algorithmischem Lernen und Berücksichtigung von Experten sehr weit verbreitet und empfehlenswert (ebd., vgl. S. 96). Die Zweiteiligkeit der Erstellung eines Bayesschen Netzes zeigt sich in der Gleichung

$$\underbrace{Pr(B|D) = Pr(G, \Theta|D)}_{\text{Lernen}} = \underbrace{Pr(G|D)}_{\text{Struktur lernen}} * \underbrace{Pr(\Theta|G, D)}_{\text{Parameter lernen}}$$

mit dem Datenset D , einem Bayesschen Netz $B = (G, X)$, dem DAG G und der Verteilung X , deren Kennzeichnung durch die Klassenzugehörigkeit aller ähnlichen Verteilungen mit Θ bezeichnet wird.

Es gibt zahlreiche Algorithmen und Methoden, um die CPT eines Bayesschen Netzes und die Struktur eines DAG zu lernen. Für diese Arbeit wird je ein Algorithmus für die Aufgaben eingesetzt. Für das Lernen der Stuktur wird der Algorithmus *Max-Min Hill-Climbing* (MMHC) eingesetzt und für das Lernen der CPT der Algorithmus Expectation-Maximization (EM).

3.5.1. Max-Min Hill-Climbing (MMHC)

Es gibt zwei grundlegende Ansätze für das Lernen der Struktur eines BN: Der Search-And-Score-Ansatz zielt darauf ab, die Score-Funktion – ein Indikator dafür, wie gut ein Netz zur vorhandenen Datenbasis passt – zu maximieren. Ein anderer Ansatz für das Lernen der Struktur eines BN prüft anhand der Datenbasis, ob die Variablen untereinander bedingte Unabhängigkeiten aufweisen. Der MMHC-Algorithmus kombiniert diese beiden Ansätze und kann somit als Hybrid-Algorithmus aufgefasst werden. MMHC lernt zuerst das 'Skelett', d.h. die Ecken ohne eine Richtung eines BNs, anhand eines lokalen Suchalgorithmus mit Namen Max-Min Parents and Children (MMPC). Danach werden die Richtungen der Verbindungen des

erlernten „Skeletts“ durch eine Suche per Greedy-Scoring Hill-Climbing ermittelt. Nachfolgend dargestellt ist ein Pseudo-Code des MMHC-Algorithmus (Tsamardinos, Brown und Aliferis 2006, vgl. S. 2f):

```

1 procedure MMHC(D)
2 Input: data D
3 Output: a DAG on the variables in D
4
5 % Restrict
6 for every variable  $X \in V$  do
7    $PC_x = MMPC(X, D)$ 
8 end for
9
10 %Search
11 Starting from an empty graph perform Greedy Hill-Climbing
12 with operators add-edge, delete-edge, reverse-edge.
13 Only try operator add-edge  $Y \rightarrow X$  if  $Y \in PC_x$ 
14 Return the highest scoring DAG found
15 end procedure

```

Wie beschrieben, benutzt der MMHC-Algorithmus einen weiteren: MMPC. Der MMPC-Algorithmus verläuft in drei Schritten (durch Petersson (2010) nach den Erkenntnissen von Tsamardinos, Brown und Aliferis (2006)):

Schritt 1: Sei T eine der Variablen in der Datenbasis. Sei $(X_i)_{i=1}^d$ eine Sortierung der übrigen Variablen und die Menge $Z_0 = \emptyset$, die leere Menge. Für $i = 1, \dots, d$ vollziehe folgendes:

$$Z_i = \begin{cases} Z_{i-1} & \text{wenn } X_i \perp T | Z_{i-1} \\ Z_{i-1} \cup \{X_i\} & \text{sonst} \end{cases}$$

Schritt 2: Sei $Z_0 = Z_d$ und $(X_i)_{i=1}^k$ eine Verteilung der Variablen aus Z_0 . Für $i = 1, \dots, k$ vollziehe folgendes:

$$Z_i = \begin{cases} Z_{i-1} \setminus \{X_i\} & \text{wenn } \exists S \subseteq Z_{i-1} \setminus \{X_i\} \text{ sodass } T \perp X_i | S \\ Z_{i-1} & \text{sonst} \end{cases}$$

Schritt 3: Für alle Variablen der Verteilung sind zunächst die Schritte 1 und 2 auszuführen. Anschließend sind die Mengen für Z_{x_i} aller Variablen X_i der Verteilung bekannt. Sei T eine dieser Variablen und $(X_i)_{i=1}^j$ eine Sortierung der Variablen in Z_T . Sei $y_0 = Z_T$. Für $i = 1, \dots, j$ vollziehe folgendes:

$$y_i = \begin{cases} y_{i-1} & \text{wenn } T_i \in Z_{x^i} \\ y_{i-1} \setminus \{X_i\} & \text{sonst} \end{cases}$$

Man setze $y_T = y_i$. Dies ist die Menge der Eltern ohne die Menge der Kinder von T (engl. Parents \ Children).

3.5.2. Expectation-Maximization (EM)

Der Algorithmus Expectation-Maximization (EM) beginnt mit einem zufälligen Erklärungsmodell Θ . Der Wert ℓ ist die untere Grenze der Zuordnung und somit die Abdeckungswahrscheinlichkeit für das Modell Θ . Der Wert ℓ ist stets ein Fragment des Modells Θ .

Nachdem ein zufälliges Θ gefunden ist, wird anschließend abwechselnd versucht, Θ zur unteren Grenze ℓ zu verschieben (Expectation-Schritt). Daraufhin wird ℓ selbst verbessert (Maximization-Schritt), sodass ℓ wieder zum veränderten Modell Θ passt.

Es wird also versucht, die Zuordnung oder Abdeckungswahrscheinlichkeit des konstruierten Modells mit der vorhandenen Datenbasis zu erhöhen. Mathematisch ausgedrückt sehen die Schritte E und M folgendermaßen aus (Ng 2017):

Zu wiederholen bis zur Konvergenz ist folgendes:

(E-Schritt) für jedes i , setze

$$Q_i(z^{(i)}) := p(z^{(i)} | x^{(i)}; \Theta).$$

(M-Schritt) setze

$$\Theta := \operatorname{argmax} \sum_i \sum_{z^{(i)}} Q_i(z^{(i)}) \log \frac{p(x^{(i)}, z^{(i)}; \Theta)}{Q_i(z^{(i)})}$$

4. Entwicklung eines Expertensystems

In diesem Kapitel wird das anschließend zu erprobende Expertensystem auf Basis eines Bayesschen Netz entwickelt. Dazu werden zuerst die vermuteten Verbindungen unter den Parametern ermittelt. Darauf basierend wird ein Modell eines Bayessches Netz erstellt, um anschließend mit Experten in Interviews über die detaillierte Ausgestaltung zu beraten. Auf dieser Basis wird daraufhin sowohl die Struktur als auch die Hinterlegung der Parameter mit CPTs durch einen hybriden Ansatz aus Lernalgorithmen und händischen Adjustierungen des Bayesschen Netzes erzeugt.

4.1. Auswahl geeigneter Module als Leistungsindikatoren zukünftiger Softwareentwickler

Kritisch gesehen werden muss die Frage, ob die ausgewählten Module gute Indikatoren für die notwendigen Kompetenzen eines angehenden Softwareentwicklers darstellen können, wie diese überhaupt aussehen und ob die Fachgebiete der unterschiedlichen Module studien-gangübergreifend miteinander verglichen werden können. Um darüber Klarheit zu verschaffen, wurden zwei Methoden gewählt: Zum einen wurde der Ansatz gewählt, mittels eines Venn-Diagramms die Modul- und Qualifikationsziele in eine logische Relation zu stellen und zu untersuchen, ob die notwendige Schnittmenge zu den Kompetenzen eines zukünftigen Softwareentwicklers bzw. Informatikers erreicht sind. Zum anderen wurden Experten dazu befragt, was einen guten Informatiker ausmacht und ob die ausgewählten Module diesen Anspruch aufzeigen können.

4.1.1. Venn-Diagramme zur grafischen Verdeutlichung

Ein Verfahren, um sich der Frage nach der Güte der ausgewählten Module zu nähern, sind Venn-Diagramme. Ein Venn-Diagramm zeigt alle möglichen logischen Überschneidungen von Mengen auf. Durch Bestimmung der Zugehörigkeit einzelner Elemente zu Schnittmengen ist

es möglich, eine Aussage über logische Verknüpfungen zu treffen. Solche Venn-Diagramme sind jedoch nach Plaue und Scherfner (2009, vgl. S. 15) nicht dafür geeignet, mathematische Beweise zu führen. Sie dienen hier lediglich der Verdeutlichung von Mengenrelationen.

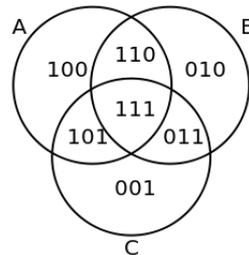


Abbildung 6.: Venn-Diagramm mit binären Mengen- und Schnittmengenbezeichnern. Quelle: Jones (2016)

Es wird nach der Aussage gesucht:

„Die Überschneidung der Qualifikationen zweier ausgewählter Mathematik- und eines Softwareentwicklungs-Moduls sind äquivalent zu mindestens einer Kernkompetenz eines Softwareentwicklers“. Aussagenlogisch ausgedrückt könnte dies heißen:

$$\text{Mathe1} \cup \text{Mathe2} \cup \text{Progr1} \supseteq \{ \text{Abstraktionsvermögen} \vee \text{Logisches Denken} \vee \text{Analytisches Denken} \vee \text{Mathematisches Verständnis} \vee \text{Algorithmisches Denken} \}.$$

Verbal ausgedrückt bedeutet die obere Aussage nichts anderes, als dass die drei ausgewählten Module je Studiengang in einer Überschneidungsmenge eine der Kompetenzen eines Informatikers *bedienen* können müssen. Im Bezug auf Abbildung 6 gilt es also, die Schnittmenge *111* je Studiengang zu finden, die eine Teilmenge aus den Kompetenzen sein muss. Die entsprechenden Textstellen aus den Modulbeschreibungen (im Anhang unter Abschnitt A.10) sind in Tabelle 2 und Tabelle 3 aufgeführt. Die entsprechende Einordnung in das Venn-Diagramm Abbildung 6 erfolgt anschließend. In Tabelle 2 sind jeweils die gleichen Module mit den gleichen Modul- und Qualifikationspassagen aufgeführt. Es wird ersichtlich, dass die mathematischen Module vor allem auf die Fähigkeiten abzielen, algorithmisches und somit auch logisches Denken zu vermitteln. Dabei geht es um Grundlagenverständnis. Das Programmiermodul soll neben den Begriffen der Informatik das Verständnis für die Objektorientierung vermitteln. Ein solches Verständnis setzt zwangsläufig ein Abstraktionsvermögen voraus. Somit lässt sich über die beiden Studiengänge Angewandte Informatik und Wirtschaftsinformatik aussagen, dass die ausgewählten Module eine Obermenge der Kompetenzen eines Informatikers bilden und somit als Indikatoren geeignet sind.

4.1. Auswahl geeigneter Module als Leistungsindikatoren zukünftiger Softwareentwickler

B.Sc.	1. Mathemodul	2. Mathemodul	Software-Modul
AInf	„Aufbau von Kenntnissen wichtiger mathematisch-struktureller Grundlagen der Informatik“. „Kenntnisse und Fertigkeiten, Problemlösungen algorithmisch zu formulieren.“	„Wissensvermittlung über Algorithmen und Mathematik von Kryptosystemen“	„Aufbau von Kenntnissen wichtiger Grundbegriffe der Informatik, insbesondere ein Verständnis der Grundkonzepte objektorientierter Programmiersprachen“
WInf	„Aufbau von Kenntnissen wichtiger mathematisch-struktureller Grundlagen der Informatik“. „Kenntnisse und Fertigkeiten, Problemlösungen algorithmisch zu formulieren.“	„Wissensvermittlung über Algorithmen und Mathematik von Kryptosystemen“	„Aufbau von Kenntnissen wichtiger Grundbegriffe der Informatik, insbesondere ein Verständnis der Grundkonzepte objektorientierter Programmiersprachen“

Tabelle 2.: Modul- und Qualifikationsziele als Schnittmenge zu den Kompetenzen zukünftiger Softwareentwickler der Studiengänge Angewandte Informatik (AInf) und Wirtschaftsinformatik (WInf). Entnommen den Modulhandbüchern aus Abschnitt A.10.

B.Sc.	1. Mathemodul	2. Mathemodul	Software-Modul
WIng	„Die Studierenden kennen und verstehen die grundlegenden mathematischen Begriffe der (linearen) Algebra und Analysis einer Variablen [...]“	„Die Studierenden werden durch die Veranstaltung in die Lage versetzt, Lösungsalgorithmen für ausgewählte Optimierungsaufgaben mit mehreren Variablen anzuwenden.“	„Kenntnis der Grundlagen der Informations- und Kommunikationstechnologie sowie der technischen Informatik, Fähigkeit, Problemlösungen algorithmisch zu formulieren.“
BWL	„Das Modul vermittelt grundlegendes mathematisches Verständnis und Fähigkeiten, die eine wissenschaftliche und quantitative Betrachtungsweise in der Betriebswirtschaftslehre erst ermöglichen.“	„Im Modul werden mathematische Fähigkeiten vermittelt, die eine unverzichtbare Grundlage für eine quantitative Betrachtung ökonomischer Sachverhalte darstellen“	„Durch die Vermittlung von Grundkenntnissen der Softwareentwicklung wird ein Verständnis für die besonderen Herausforderungen der Programmierung geschaffen.“

Tabelle 3.: Modul- und Qualifikationsziele als Schnittmenge zu den Kompetenzen zukünftiger Softwareentwickler der Studiengänge Wirtschaftsingenieurwesen (WIng) und Betriebswirtschaftslehre (BWL). Entnommen den Modulhandbüchern aus Abschnitt A.10.

Tabelle 3 zeigt die entsprechenden Passagen der Modul- und Qualifikationsziele der Studiengänge Wirtschaftsingenieurwesen und Betriebswirtschaftslehre an der FH Nordakademie auf. Bei den mathematischen Modulen des Wirtschaftsingenieurwesens wird zum einen vom Grundlagenverständnis mathematischer Begriffe und zum anderen von Lösungsalgorithmen gesprochen. Beides ist der Abstraktions- als auch Logikkompetenz zuzuordnen. Das Programmiermodul zielt ebenfalls auf die Fähigkeit ab, Problemlösungen algorithmisch formulieren zu können.

Die Mathematikmodule der Betriebswirtschaftslehre vermitteln grundlegendes mathematisches Verständnis, sowie Fähigkeiten zur quantitativen Betrachtung ökonomischer Sachverhalte. Diese Kompetenzen setzen Abstraktionsvermögen voraus sowie die Fähigkeit, algorithmisch zu denken. Das Programmiermodul vermittelt die Grundkenntnisse der Softwareentwicklung und erfordert somit logisches Denken.

Somit ist auch für die Bachelorstudiengänge Wirtschaftsingenieurwesen und Betriebswirtschaftslehre aufgezeigt, dass die Schnittmenge von Modul- und Qualifikationszielen eine Obermenge der zuvor ermittelten Menge von Kompetenzen eines Informatikers darstellt. Diese Modulauswahl stellt sich somit als gültiger Indikator für die Befähigung zur Softwareentwicklung heraus.

4.1.2. Verifikation durch Experten

Wie in Abschnitt 4.5 weiter beschrieben wird, wurden für diese Untersuchung die ermittelten Module Experten in Interviews vorgestellt. Es wurde darüber diskutiert, inwiefern diese Module gültige Indikatoren sein können.

Insgesamt stimmten die Experten mit den Modulen überein. Es wurde darauf hingewiesen, dass die Prüfform der Module einen großen Einfluss haben kann. So zeigte sich, dass die Softwareentwicklungsmodule der Wirtschaftsingenieure und Betriebswirte durch eine Hausarbeit abgeschlossen werden. Dabei werden in Gruppen Softwareprodukte erstellt. Dies gilt aber nicht für das Modul *Programmierung 1* der Wirtschaftsinformatiker und Angewandten Informatiker. Das Modul *Programmierung 2* ist ebenfalls eine solche Hausarbeit. In der Modulbeschreibung zu *Programmierung 2* unter Abschnitt A.10 wird das Qualifikationsziel beschrieben mit: „Kenntnisse und Fertigkeiten zur algorithmischen Problemformulierung“, was den Modulzielen des Moduls *Programmierung 1* ähnlich ist und auf den erworbenen Fähigkeiten aus *Programmierung 1* aufbaut. Somit ist auch dieses Modul ein legitimer Indikator für die grundlegende

Eignung zukünftiger Softwareentwickler.

4.2. Datenerhebung und statistische Voruntersuchung

Für die erfolgreiche Gestaltung und Verwendung eines Expertensystems auf Basis von maschinellem Lernen sind Daten ausreichender Qualität und Quantität unabdingbar. Nachfolgend wird daher aufgeführt, wie die Datenqualität der empirischen Untersuchung zu bewerten ist. Ferner geht es um die Frage, welche Quantität für welche Art der Untersuchung notwendig ist. Dabei werden die Daten weitestgehend in der 'Rohform' untersucht, d.h. es wurden noch keine Standardisierungen o.Ä. durchgeführt. Einzig das Notenschema der Module wurde auf das 15-Punkte-System übertragen, um die Anschaulichkeit der Scatter-Plots zu erhöhen.

Für jede wissenschaftliche Datenuntersuchung ist zuerst darzulegen, wie die Daten erhoben wurden und welche etwaigen Mängel es am Erhebungsverfahren geben könnte, um auf einen möglichen Fehler der Aussagen aufmerksam zu machen.

Ein Bayessches Netz ist nur dann von Vorteil, wenn die klassische Statistik keine ausreichenden Antworten zu Zusammenhängen der Daten erbringen kann, sodass unsicher quantifiziert werden muss (Russell und Norvig 2012, Vgl. S. 586). Um zu prüfen, zu welchen Aussagen die klassische Statistik kommt, werden die Daten nachfolgend auf Maßzahlen der Lage und Streuung, sowie auf lineare Zusammenhänge hin untersucht. Diese Werte können nach Kolanoski (2008, Vgl. S. 7ff, S. 44ff) als Auswahl grundlegender Untersuchungsmethoden der deskriptiven Statistik angesehen werden.

4.2.1. Datenerhebung

Seit 2012 erfordert das Studium an der FH Nordakademie von den Studienanwärtern, einen Auswahltest zu absolvieren. Dieses Auswahlverfahren umfasst die Schulleistungen der Fächer Deutsch, Mathe und Englisch der letzten vier Schulsemester eines Bewerbers, einen Persönlichkeitstest, einen Test mit fachlichen Grundlagenfragen zum jeweiligen Studiengang, einen Englisch- und Mathematiktest sowie einen Intelligenzstruktur- und Motivationstest (Plate 2016a, vgl.). Diese Auswahlverfahren durchlaufen die Studierenden der Bachelorstudiengänge Betriebswirtschaftslehre, Wirtschaftsinformatik, Wirtschaftsingenieurwesen und seit 2015 Angewandte Informatik (alle Bachelor of Science), wie sie auf der Homepage der Nordakademie

beschrieben sind (Plate 2016b).

Durchgeführt wird der Auswahltest durch die Studierenden an einem beliebigen, internetfähigen Gerät. Nach der Registrierung erhalten die Studieninteressierten eine virtuelle Identifikation (auch: Token), mit welcher das Testprozedere in einem Browser durchlaufen werden kann. Dabei werden die Studieninteressierten darüber belehrt, dass Hilfsmittel wie beispielsweise ein Taschenrechner im Mathematiktest oder ein Wörterbuch während des Englischtests nicht genutzt werden dürfen. Ferner erklären sich die Studieninteressierten damit einverstanden, dass Daten durch die Nordakademie erfasst und gesichert werden dürfen.

4.2.2. Struktur und Skalierung der Daten

Alle Resultate und einige Zwischenergebnisse dieses Auswahlverfahrens werden auf den Servern der Nordakademie gesichert und wurden dem Autor in aufbereiteter und anonymisierter Form zur Verfügung gestellt. Viele der Felder des Datenbankabzugs erweisen sich als für diese Untersuchung irrelevant. So wurden einzelne *Items* des Visual Questionnaire (ViQ), deren Erhebung weder vorliegt noch für die Untersuchung relevant ist, vom zu untersuchenden Datenbestand entfernt. Auch Datensätze mit fehlenden Einträgen, die ansonsten die Objektivität der Untersuchung behindern würden, wurden entfernt. Ein reduzierter Datensatz, der exemplarisch für alle zu untersuchenden Datensätze steht, ist dargestellt in Tabelle 4. Ein kompletter Datensatz in Rohform, wie er von der Hochschule zur Verfügung gestellt wurde, befindet sich in Tabelle 13 (Seite 88).

Wie in Abschnitt 4.1 beschrieben, wurden drei ausgewählte Module eines jeden Studierenden identifiziert, die als Indikator für die Fähigkeit zum logischen Denken und technischen Verständnis dienen sollen. Da mathematische Disziplinen mit viel logischem Verständnis einhergehen, wurden zwei Module zu mathematischen Grundlagen und ein Modul zu Grundlagen aus der Softwareentwicklung oder Datenverarbeitung gewählt. Das Software-Modul wird nicht als Klausur, sondern Programmier-Hausarbeit geprüft. In Tabelle 5 ist aufgeführt, welche Module für welchen Studiengang zu einem Untersuchungsdatensatz hinzugefügt wurden.

Indikator	Wert	Indikator	Wert
id	490	mix_leistung	75
fachbereich	BWINF	mix_bindung	69
m/w	w	mix_macht	80
alter	18	iqt_gesamt	95
deutsch_1	10	iqt_sprache	78
deutsch_2	10	iqt_merkfaehigkeit	99
deutsch_3	11	iqt_logik	88
deutsch_4	11	iqt_rechnen	96
deutsch_durchschnitt	10,5	iqt_technik	80
englisch_1	11	viq_s	1,3
englisch_2	11	viq_n	-1,26
englisch_3	9	viq_t	2,02
englisch_4	11	viq_f	-0,15
englisch_durchschnitt_abi	10,5	viq_j	1,15
mathe_1	13	viq_e	0,89
mathe_2	12	mathe	80
mathe_3	12	student_id	4970
mathe_4	14	mathe1_modul	7,1
mathe_durchschnitt	12,75	mathe2_modul	10,1
gesamt_durchschnitt	11,25	progr_modul	8,9
englisch_durchschnitt_bsc	0,6	Mittelwert	8,7

Tabelle 4.: Auszug eines reduzierten Datensatzes. Es fehlen drei Betrachtungsmodule je eines Studierenden. Ferner wurden einige Werte bereits transformiert, wie die Modulergebnisse. Erfasst und zur Verfügung gestellt durch Prof. Dr. David Scheffer (2016).

Wie bereits der Tabelle 4 zu entnehmen ist, bestehen die psychosozialen Indikatoren aus dem *ViQ*, dem *MIX* und dem *IQt*, deren Bedeutung in Abschnitt 2.5 erläutert werden. Daneben finden sich im dargestellten, reduzierten Datensatz die schulischen Leistungen der letzten vier Semester für die Fächer *Mathematik*, *Deutsch* und *Englisch*, sowie der Durchschnitt der *Fachhochschulreife* (hier *gesamt_durchschnitt* genannt). Ebenfalls kognitive Faktoren sind der *Mathematik*- (hier *mathe* genannt) und *Englishtest* der Hochschule. Fachfragen wurden mangels Vergleichbarkeit entfernt. Zuletzt werden zu jedem Studierenden personenbezogene Daten wie Geschlecht und Fachbereich erfasst.

Studiengang	Mathemodul 1	Mathemodul 2	Softwaremodul
BWL	Wirtschaftsmathe 1	Wirtschaftsmathe 2	Einführung EDV
WInf	Diskrete Mathe. 1	Diskrete Mathe. 2	Program. 1
WIng	Ingenieursmathe	Wirtschaftsmathe	Einf. Softwareentw.
AInf	Diskrete Mathe. 1	Diskrete Mathe. 2	Program. 1

Tabelle 5.: Auswahl geeigneter Module als Leistungsindikatoren des logischen Denkvermögens.

BWL: B.Sc. Betriebswirtschaftslehre. WInf: B.Sc. Wirtschaftsinformatik. WIng: B.Sc. Wirtschaftsingenieurwesen. AInf: B.Sc. Angewandte Informatik, erstellt anhand von Modulzielen aus den Modulbüchern in Abschnitt A.10 (2016).

Die Werte *Geschlecht* und *VIQ-Typ* liegen in *Nominalskala* vor. Bei einer nominal skalierten Werten können lediglich Aussagen über Gleichheit oder Andersartigkeit einer Ausprägung im Vergleich zu anderen Ausprägungen getroffen werden.

Notenpunkte wie die *letzten vier Schulsemester* oder die *Modulergebnisse* liegen in einer *Ordinalskala* vor, sind somit unterscheidbar und besitzen eine Rangfolge. Bei ordinal skalierten Werten existiert allerdings kein natürlicher Nullpunkt. Es lassen sich außerdem keine qualitative Aussagen neben einer bloßen Rangfolge treffen. 12 Punkte in einer schulischen Klausur bedeuten beispielsweise gegenüber 6 Punkten zwar, dass der Schüler mit 12 Punkten besser war als jener mit 6. Allerdings heißt das nicht, dass der Schüler genau doppelt so intelligent ist, da es sich bei den bepunkteten Aufgaben um unterschiedliche Fragestellungen handelt.

Der Wert *Alter* sowie Prozentwerte wie *die Mix-Werte, der IQ, der Mathematik- und Englisch-Test* liegen in der *Verhältnisskala* vor. Die verhältnisskalierten Werte sind kardinal messbar, was bedeutet, dass die Werte eine Rangfolge ausdrücken. Dazu kommt bei verhältnisskalierten Werten, dass sie einen sachlogischen Nullpunkt besitzen (Schira 2012, Vgl. S. 23).

Der *ViQ* ist z-standardisiert und entspricht somit einer Normskala. Diesen Skalen ist gemein, dass sie von einer normverteilten Z-Skala abgeleitet sind. Berechnet werden sie durch die Anweisung (ebd., S. 285):

$$Z := \frac{X - \mu}{\sigma}$$

Für die Interpretation ist entscheidend, welcher Erwartungswert μ und welche Standardabweichung σ für die untersuchte Zufallsvariable X vorliegen. Eine Standardisierung wird vorgenommen, wenn Werte unterschiedlicher Maßeinheiten vergleichbar gemacht werden sollen.

Für univariate statistische Aussagen sind die einzelnen Skalen wenig relevant. Wesentlich sind die Skalenniveaus der einzelnen Variablen allerdings bei bivariaten statistischen Aussagen wie dem linearen Zusammenhang zweier Variablen oder der Korrelation. Die Skalierung einzelner Variablen ist in Tabelle 6 aufgelistet auf.

Wert	Skala
Alter	Verhältnis
Geschlecht	Nominal
Studiengang	Nominal
Schulnoten	Ordinal
Mathetest	Verhältnis
Englishtest	Verhältnis
MIX	Verhältnis
IQt	Verhältnis
ViQ	Norm
Modulnoten	Ordinal

Tabelle 6.: Werte-Typen und zugehörige Skalen

4.2.3. Quantität und Qualität der Daten

Wie eingangs in diesem Abschnitt erwähnt, liegen Daten zu allen Studierenden seit 2012 in drei Studiengängen sowie seit 2014 zusätzlich zum Studiengang Angewandte Informatik vor, der zuvor von der Nordakademie nicht angeboten wurde. Viele Werte werden für alle Studierenden gleich erhoben und lassen sich somit vergleichen. Würden exakte Studienergebnisse miteinander verglichen werden, dürfte dies streng genommen nur für exakt gleiche Prüfungen erfolgen. Hat ein Fach in unterschiedlichen Jahrgängen verschiedenartige Prüfungen, kann dies bereits die Aussage verfälschen.

Die Leistungsmetrik dieser Arbeit bezieht sich nicht auf einzelne Prüfungsergebnisse, sondern auf die generelle Befähigung zum mathematisch-logischen Denken. Die befragten Fachexperten aus Abschnitt 4.5 bestätigten weitestgehend, dass die ausgewählten zwei Mathematik-Module und das eine Software-Modul eines jeden Studiengangs dafür Indikatoren seien. Daher lassen die Ergebnisse dieser Module den Vergleich der Qualifikationsziele untereinander zu. Werden die Rohdaten so selektiert und gefiltert, dass nur noch untereinander gleiche Erhebungen und die drei ausgewählten Module betrachtet werden, lassen sich die Datensätze aggregieren. Auf diese Weise erhöht sich der Bestand betrachteter Datensätze auf 1.114.

Vor allem für die Untersuchung durch Bayessche Netze ist es wichtig, dass nur sinnvolle Daten und vollständige Datensätze betrachtet werden. So müssen einzelne Datensätze herausgenommen werden, bei denen wichtige Werte fehlen. Werte fernab der Erwartungswerte (sprich: *extreme Ausreißer*) oder Werte, die nicht den überhaupt möglichen Werten der Metrik entsprechen – so z.B., wenn ein Wort hinterlegt ist, obwohl eigentlich eine Fließkommazahl erwartet wird, müssen entfernt werden. Auch unplausible Werte sind aus Datensätzen zu entfernen. Unter dem Alter befanden sich Extremwerte wie 819 oder 0. Beide Angaben sind als menschliches Alter unsinnig und daher aus den Daten zu entfernen. Eingabefehler können zu unsinnigen Datensätzen führen. So befinden sich unter den Daten mehr als zehn Datensätze, bei denen die durchschnittliche Punktzahl einzelner Oberstufenfächer bei circa zwei liegt. Offensichtlich wurde die Eingabe von Punkten als Eingabe von Notenwerten missverstanden. Auch diese fehlerhaften Datensätze müssen für sinnvolle Gesamtaussagen aus dem Datenbestand entfernt werden. Die aggregierten Rohdaten wurden um diese unzureichenden Einträge bereinigt, wonach noch 922 Datensätze mit 50 Variablen zur Verfügung stehen.

4.2.4. Beschreibende univariate Statistik

Um sich eine generelle Vorstellung von der Beschaffenheit der Daten machen zu können, sind einige vergleichsweise triviale Maße hilfreich. Dazu gehören die Extremwerte *Maximum* und *Minimum*. Diese beiden Maße beinhalten jeweils das rang-höchste und rang-niedrigste Element einer Menge bzw. die Elemente, für die gilt, dass es kein größeres / kleineres Element in der gegebenen Menge gibt (Bosch 1999, S. 529).

Das arithmetische Mittel ist allgemein bekannt als *Durchschnitt* und bezeichnet den Mittelwert, der als Verhältnis aus der Summe aller Elemente zu deren Anzahl berechnet wird. Mathematisch ausgedrückt lautet er wie folgt (Schira 2012, S. 43):

$$\bar{x} = \frac{1}{n} \sum_{j=1}^n x_j$$

Der Median unterscheidet sich insofern vom arithmetischen Mittel, als dass kein Verhältnis betrachtet wird, sondern das Element, das in der Ordnungsrelation genau mittig angeordnet ist, sodass ebenso viele Elemente in der Ordnung darüber wie darunter angesiedelt sind. Mathematisch ausgedrückt bedeutet dies (Bourier 2014, S. 72):

Sei (x_1, x_2, \dots, x_n) eine geordnete Stichprobe. Dann ist der Median \tilde{x} :

$$f(n) = \begin{cases} x_{\frac{n+1}{2}} & n \text{ ungerade} \\ \frac{1}{2} (x_{\frac{n}{2}} + x_{\frac{n}{2}+1}) & n \text{ gerade.} \end{cases}$$

Ein ebenfalls wichtiges Lagemaß ist das *Quantil*. Ein Quantil unterteilt eine statistische Reihe, sodass eine festgelegte Prozentzahl aller Elemente einer Menge sich darin befinden. Mathematisch definieren lässt sich ein *q-Quantil* wie folgt (Schira 2012, S. 59):

Eine Zahl $x_{[q]}$ mit $0 < q < 1$ heißt *q-Quantil*, wenn sie die statistische Reihe X so aufteilt, dass mindestens $100 * q\%$ ihrer Beobachtungswerte kleiner oder gleich $x_{[q]}$ sind und gleichzeitig mindestens $100 * (1 - q)\%$ größer oder gleich $x_{[q]}$ sind, also

$$relH(X \leq x_{[q]} \geq q) \quad \text{und} \quad relH(X \geq x_{[q]} \geq 1 - q).$$

Weitere zwei univariate statistische Maße sind die Varianz und die Standardabweichung, die miteinander in Relation stehen. Dabei geht es um die Streuung der Werte einer Menge von dem

zu erwartenden Wert einer Zufallsvariable aus ebendieser Menge.

Mit σ^2 (σ^2) wird die Varianz, mit σ (σ) die Standardabweichung ausgedrückt. Die Varianz ist die Summe aller Quadrate der Entfernungen zum Mittelwert (Bourier 2014, S. 97):

$$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2,$$

wobei n die Anzahl aller Merkmalswerte x ist, \bar{x} das arithmetische Mittel darstellt und i die Laufvariable der Summe.

Diese Maßzahlen der univariaten Statistik wurden für die gegebenen Daten der Studierenden ermittelt und in Tabelle 9 aufgeführt.

4.2.5. Beschreibende bivariate Statistik

Anders als bei der univariaten Statistik, werden bei der bivariaten Statistik mehrere Variablen und deren Zusammenhänge zueinander betrachtet. Häufig ist von Interesse, ob mehrere Variablen miteinander im Zusammenhang stehen, sodass das Verhalten einer Variable bereits Aufschluss über das zu erwartende Verhalten einer anderen Variable gibt.

Ein grundlegendes Maß ist die Kovarianz, die beschreibt, ob ein monotoner Zusammenhang zwischen zwei Zufallsvariablen besteht. Dies drückt sich darin aus, dass hohe / niedrige Werte der einen Variable mit hohen / niedrigen Werten einer anderen Variable einhergehen, also eine gleiche *Tendenz* auf deren Scatterplot zu erkennen ist. Berechnet wird die Kovarianz wie folgt:

„Die aus n Wertepaaren (x_i, y_i) berechnete Größe

$$c_{xy} := \frac{1}{n} \sum_{j=1}^n (x_j - \bar{x})(y_j - \bar{y})$$

heißt *empirische Kovarianz*, oder kurz *Kovarianz*, zwischen den statistischen Variablen X und Y “ (Schira 2012, S. 92).

Häufig genutzt werden s.g. Korrelationskoeffizienten. Diese Maßzahlen sind der Ausdruck des linearen Zusammenhangs zwischen Variablen. Entscheidend dabei ist die Skalierung der vorliegenden Daten. So müssen Werte für die Untersuchung auf Korrelation mindestens ordinalskaliert sein. Ferner wird für ordinalskalierte Variablen der Rangkorrelationskoeffizient

nach Spearman, für intervall- oder verhältnisskalierte Variablen der Korrelationskoeffizient nach Pearson genutzt (für alle Korrelationskoeffizienten: ρ). Bei der bivarianten Statistik lassen sich Untersuchungen unterschiedlich skalierten Variablen stets mit den Untersuchungen für die rangniedrigere Skalierung nutzen. Liegen daher zwei Variablen einmal ordinal- und verhältnisskaliert vor, so lassen sich alle Untersuchungen für ordinalskalierte Variablen für diese beiden Variablen durchführen (Kolanoski 2008, vlg. S. 96f.).

Definiert wird der Spearman Rangkorrelationskoeffizient wie folgt:

$$\rho_s = 1 - \frac{6 * \sum_{i=1}^n (r_i - s_i)^2}{n^3 - n}$$

mit

r_i = Rangplatz innerhalb der Variable X de[r] i-ten [Entität]

s_i = Rangplatz innderhalb der Variable Y de[r] i-ten [Entität] und

n = Anzahl [Entitäten] (Schwarz und Bruderer Enzler 2016).

Der Korrelationskoeffizient nach Pearson findet weit häufiger Benutzung als der Rangkorrelationskoeffizient nach Spearman. Er kann für alle mindestens kardinalskalierten Variablen genutzt werden. Berechnet wird er wie folgt (Schira 2012, S. 95):

$$r_{XY} := \frac{C_{XY}}{S_X * S_Y}$$

Aufschlussreich ist ferner der *Chi-Quadrat* (χ^2) Unabhängigkeitstest. Dieser prüft die Hypothese, ob zwei Variablen voneinander unabhängig sind. Wird die Nullhypothese angenommen, bedeutet dies, dass zwei Variablen mit hoher Wahrscheinlichkeit miteinander im Zusammenhang stehen. Dabei wird allgemein ein Signifikanzniveau von 5% angenommen, was einem Alpha (α)-Fehler von 0,05 entspricht (Keller 2015, vgl.). Liegt der p-Wert des χ^2 Unabhängigkeitstests demnach bei $p < 0,05$ (dem α -Fehler), dann wird die Nullhypothese abgelehnt, dass die Variablen unabhängig sind. Somit sind die Variablen in diesem Fall mit aller Wahrscheinlichkeit abhängig voneinander.

Mathematisch definiert wird der Test folgendermaßen (Schira 2012, S. 522):

$$\sum_{i=1}^k \sum_{j=1}^l \frac{(n_{ij} - E_{ij})^2}{E_{ij}} > \chi_{(k-1)(l-1)}^2 [1 - \alpha] \Rightarrow \neg H_0$$

Das *Bestimmtheitsmaß* ist das Quadrat der Korrelationskoeffizienten. Je größer das Bestimmtheitsmaß ist, desto besser beschreibt eine Variable die Varianz einer anderen Variable. Grafisch ausgedrückt: Fällt das Bestimmtheitsmaß mit $R^2 = 1$ absolut aus, liegen alle Punkte eines Scatterplots auf der Regressionsgeraden. Bei $R^2 = 0$ liegt kein Punkt darauf.

„Das Verhältnis der in einer linearen Regression erklärten Varianz zur Gesamtvarianz der abhängigen Variable Y

$$R^2 := \frac{s_{\hat{Y}}^2}{s_Y^2}$$

heißt *Bestimmtheitsmaß* der linearen Regression“ (Schira 2012, S. 113)

Ferner zeigt der nachfolgende Zusammenhang, dass das Bestimmtheitsmaß das Quadrat des Korrelationskoeffizienten ist (ebd., S. 115):

$$R^2 = \frac{b^2 s_X^2}{s_Y^2} = \left(\frac{c_{XY}}{s_X s_Y} \right)^2 = r_{XY}^2$$

Es ist zu beachten, dass die Modulergebnisse in den Noten der Werteskala [1, 5] vorliegen, wobei die Ziffer 1 dem Prädikat „sehr gut“, die 2 einem „gut“ etc. entspricht. Die Schulleistungen der ersten vier Semester liegen jedoch im Punktesystem der Skala [1, 15] vor, wobei in Dreierschritten das Prädikat „sehr gut“ für Werte 15 bis 13, „gut“ für Werte 12 bis 10 etc. vergeben werden. Wenn dazu ein Korrelationskoeffizient ermittelt wird, ergibt sich eine *Antikorrelation*, also ein negativer Korrelationskoeffizient. Dies ergibt Sinn, heißt es doch: Je höher die Abitur-Punkte sind, desto niedriger die Modulnote (und somit ebenfalls besser). Es ist jedoch sehr unintuitiv. Intuitiver wäre ein gleiches Wertmaß. Um beide Werte für die statistische Interpretation auf ein gleiches Maß zu bringen und die Anschaulichkeit der Scatter-Plots zu erhöhen, wurden die Modulergebnisse wie folgt nach einer Reihengleichung transformiert:

$$-3(n) + 17 = f(n)$$

Die ermittelten Werte, stets im Zusammenhang mit dem arithmetischen Mittel der drei Modulergebnisse je Studiengang, sind in Tabelle 10 aufgeführt. Korrelationen verändern sich auch nach Transformationen nicht. Ferner wurden die originalen Werte der Modulergebnisse für das Bayessche Netz pro Manipel (d.h. Jahrgang) z-standardisiert, um die Vergleichbarkeit zu erhöhen. Davon wurde in diesem statistischen Abschnitt abgesehen, da die Statistik lediglich dem Grundverständnis über die Datenlage und -qualität dient und diese vor allem „menschenslesbar“ sein sollte, was bei z-standardisierten Werten nicht der Fall ist.

Für die Analyse und Interpretation von statistischen Zusammenhängen ist die grafische Betrachtung der Datenmengen ein wichtiges Werkzeug. Durch die Visualisierung ist es möglich, Muster und Zusammenhänge zu erkennen. Ferner lassen sich so auch Anhaltspunkte für weitere statistische Untersuchungen abschätzen. Zu diesem Zweck wurden die *Scatterplots* der Variablen *Mittelwert der Modulergebnisse aus einem ersten Mathematik-, zweiten Mathematik- und einem einführenden Software-Modul* in einem kartesischen Koordinatensystem abgebildet. Die Abbildung 7 zeigt eine Übersicht der wichtigsten Parameter im Zusammenhang mit den drei Modulergebnissen

Zur genaueren Betrachtung befinden sich einzelne Plots im Anhang unter Abschnitt A.4 abgebildet: Die Abbildung 16 stellt den Zusammenhang zwischen Modulergebnissen und der Hochschulreife dar. Der Mathematiktest der Nordakademie im Zusammenhang mit den Modulergebnissen ist in Abbildung 17 dargestellt. Die Gesamtergebnisse des IQT im Zusammenhang mit den Modulergebnissen zeigt Abbildung 18, die der MIX-Leistung Abbildung 19 und des ViQ der Dimension Thinking Abbildung 20. Dies ist nur eine kleine Auswahl an Plots, die allerdings zum einen wichtige Werte unter den verfügbaren Variablen darstellen und repräsentativ für diese Art von Variablen sind. So stellen sich die übrigen ViQ-Werte der Ausprägung Thinking ähnlich dar. Die Interpretation der ermittelten uni- und bivariaten Werte sowie dieser Scatterplots ist Gegenstand des nachfolgenden Abschnitts zur Interpretation der bivariaten Statistikmaßzahlen.

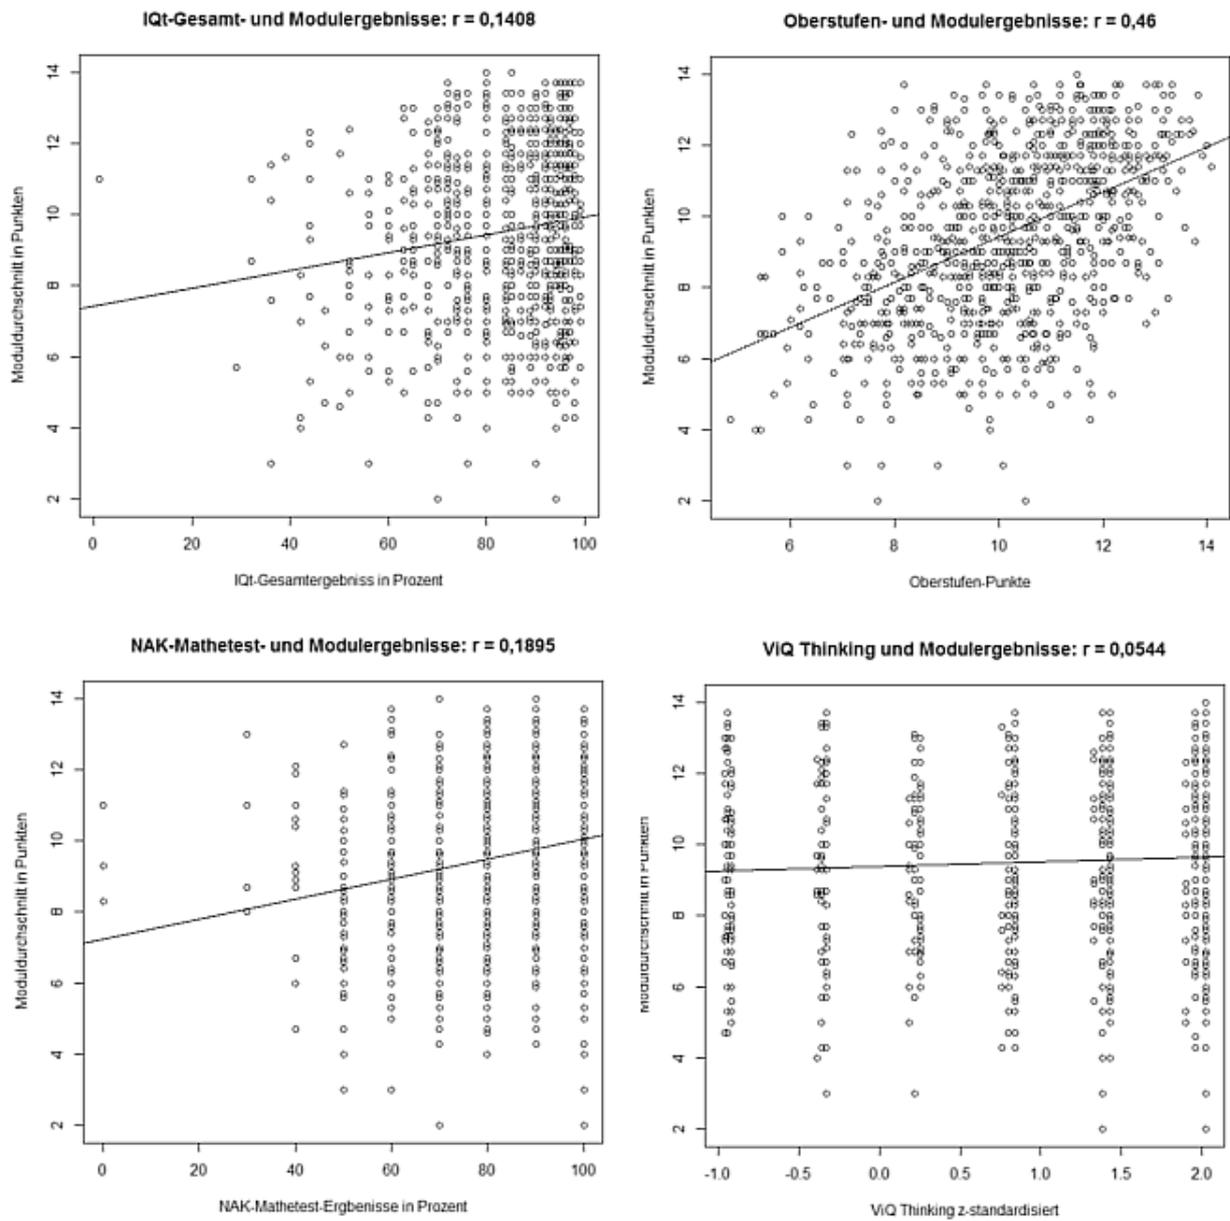


Abbildung 7.: Scatterplots mit Regressionsgeraden. Oben links: IQT zu Modulen. Oben rechts: Abitur zu Modulen. Unten links: NAK-Mathematik-Test zu Modulen. Unten rechts: ViQ Thinking zu Modulen.

4.2.6. Multiple lineare Regression

Die Regression, welche bereits in Tabelle 10 für einige Variablen berechnet wurde, gibt an, wie wahrscheinlich ein vermuteter Zusammenhang zwischen einer unabhängigen und einer abhängigen Variable (in diesem Fall das Mittel der Modulergebnisse) ausfällt. Je näher das Bestimmtheitsmaß R^2 am Wert 1 liegt, desto besser erklären die unabhängigen Variablen der multiplen linearen Regressionsanalyse die abhängige (d.h. zu erklärende) Variable.

Es ist neben der Regressionsanalyse mit einer abhängigen und einer unabhängigen Variable weiter möglich, mehrere unabhängige Variablen zu nutzen und so evtl. ein Zusammenwirken der Variablen aufzuzeigen. Dadurch kann das Bestimmtheitsmaß anwachsen. Durch die Methode der kleinsten Quadrate soll der Fehler der Regression minimiert werden:

$$SQA(a, b_1, \dots, b_k) = \sum_{i=1}^n \left(y_i - \left(a + \sum_{j=1}^k b_j x_{ji} \right) \right)^2 = \min!$$

Schira (2012, S. 555) definiert den multiplen Korrelationskoeffizient als die positive Wurzel aus R^2 , was folgendermaßen definiert ist:

$$R^2 := \frac{s_Y^2}{s_y^2} = 1 - \frac{e'e}{y'y - \bar{y}^2}.$$

Es soll weiter kritisch angemerkt werden, dass sich die Tauglichkeit einer Modellspezifikation nicht allein nach der Größe ihres Bestimmtheitsmaßes beurteilen lässt, da es sich in aller Regel durch das Hinzufügen einer beliebigen weiteren exogenen Variable vergrößert (ebd., vgl. S. 555). Das bedeutet, dass sich das Bestimmtheitsmaß durch weitere unabhängige Variablen vergrößert, da dadurch die Varianz kompensiert wird. Dies ist aber kein zwangsläufiger Indikator dafür, dass der tatsächliche Zusammenhang vergrößert wird. Deshalb ist die Bestimmtheit der multiplen Regression nur dann als Verbesserung zu erachten, wenn sich der Wert stark in Richtung der 1 bewegt. Es wurden verschiedene Kombinationen von unabhängigen Variablen zur multiplen linearen Regressionsanalyse der abhängigen Variable *durchschnittliches Modulergebnis* aufgeführt. In Tabelle 7 wurden verschiedene Kombinationen ohne den Notendurchschnitt aus der Hochschulreife zur Regressionsanalyse genutzt. In Tabelle 8 wird der Notendurchschnitt einmal als einzige unabhängige Variable aufgeführt und einmal in Kombination mit verschiedenen weiteren unabhängigen Variablen.

Aus den beiden Tabellen wird ersichtlich, dass die bestmögliche Kombination unabhängiger Variablen ohne den schulischen Notendurchschnitt R^2 auf maximal $\sim 0,031$ verbessert. Der Wert setzt sich aus den Werten Alter, der Mix-Leistung, IQt-Logik, IQt-Technik, VIQ-t und VIQ-e zusammen. Zum einen ist dieser Wert weiterhin enorm niedrig. Zum anderen zeigt bereits die Menge an unabhängigen Variablen, dass die größere Aufklärung der Varianz durch die größere Menge an Variablen zustande kommt.

Wird die lineare Regression mit den Moduldurchschnittsnoten als abhängige und den durchschnittlichen schulischen Leistungen als unabhängige Variable betrachtet, so beläuft sich R^2 auf 0,215. Somit ist bereits das Bestimmtheitsmaß aus den schulischen Notenwerten weit höher, als durch die nicht-kognitiven Parameter. Durch Hinzunahme der korrelationsstärksten Variablen aus Tabelle 10, dem IQt-Gesamt und dem NAK Mathetest, verbessert sich das Bestimmtheitsmaß R^2 auf maximal 0,234. Somit ist die Verbesserung positiv relevant, dennoch ist die Verbesserung minimal.

Variablen	Vektor-Nr	Auswahl (Vektor-Nr)	R^2
mix_leistung	22	4,22,28,30,33,36	0,0308
iqt_logik	28	4,22,28,30	0,0268
iqt_technik	30	22,28,33	0,0279
viq_t	33	4, 30, 36	0,0049
viq_e	36	4, 22,28,33	0,0280
alter	4	28, 33	0,0237

Tabelle 7.: Multiple Regression ohne Notenwerte. Die Spalte „Vektor-Nr“ gibt an, welchem Vektor die Variable links davon entspricht. In der Spalte „Auswahl“ sind dann alle Vektoren angegeben, die als unabhängige Variablen zur multiplen Regressionsanalyse des Moduldurchschnitts genutzt wurden.

Variablen	R^2
durchschnitt_gesamt	0.215
durchschnitt_gesamt, iqt_gesamt	0.225
durchschnitt_gesamt, iqt_gesamt, mathe_test	0.234

Tabelle 8.: Multiple Regression mit Notenwerten

4.2.7. Statistische Interpretation der univariaten Maßzahlen

Nachdem die uni- und bivariate beschreibende Statistik im vorangegangenen Abschnitt erläutert und anhand der Daten durchgeführt wurde, soll in diesem Abschnitt mit der Interpretation und Auslegung der ermittelten Werte behandelt werden.

In Tabelle 9 sind die univariaten statistischen Maßzahlen für ausgewählte Variablen aufgeführt. Die *Extremwerte* an sich geben lediglich Aufschluss über die Elemente einer oberen bzw. unteren Schranke gemäß der mathematischen Definition. Ein Augenmerk der Extremwertuntersuchung liegt auf den ViQ-Variablen. Sie weisen Negativwerte als Infimum auf. Dies liegt an deren Standardisierung. Für die weitere Untersuchung ist die Standardisierung jedoch wenig relevant, da dadurch Regressions- und Korrelationswerte nicht beeinflusst werden. So merkt Schira (2012, S. 285) dazu an, dass die Wahrscheinlichkeitsmuster durch die Standardisierung der ursprünglichen Zufallsvariable natürlich in keiner Weise verändert werden.

Für die Betrachtung von Extremwerten ist es wichtig zu wissen, in welcher Einheit die Variablen vorliegen. So ist z.B. das Alter in Lebensjahren angegeben, der Wert „englisch_bsc“ im Intervall $[0, 1]$.

Das *arithmetische Mittel* \bar{x} ist vor allem im direkten Vergleich zu den Extremwerten *Min* und *Max* interessant. An diesen Werten lässt sich ablesen, in welchem Rahmen sich die Ausprägungen bewegen. So fällt beispielsweise auf, dass die Mathematik-Resultate der Oberstufe zwar im Intervall $[2.5, 15]$ auftreten, das Groß der Werte jedoch mit 10,85 Punkten im Bereich „gut“ des Notensystems angesiedelt ist. Auffällig beim arithmetischen Mittel ist zum einen, dass der Mix-Wert „Macht“ relativ niedrig ausgeprägt ist und die Resultate des Nordakademie-Mathematik-Tests mit mehr als 80% verhältnismäßig hoch ausfallen, wenn man daneben die durchschnittlichen Modulergebnisse von 9,25 – gerundet „befriedigend“ betrachtet.

Wert	Min	$Q_{0.25}$	x_{med}	\bar{x}	$Q_{0.75}$	Max	σ^2	σ
alter	16,00	18,00	19,00	19,34	20,00	42,00	6,68	2,58
deutsch_durchs	4,25	8,25	10,00	9,78	11,25	14,50	4,01	2,00
englisch_durchs	4,00	8,33	10,00	9,82	11,33	14,50	4,49	2,12
mathe_durchs	4,00	9,50	11,00	10,89	12,75	15,00	5,20	2,28
gesamt_durchs	4,83	9,00	10,25	10,17	11,50	14,08	3,05	1,75
englisch_bsc	0,20	0,47	0,60	0,59	0,73	1,00	0,03	0,17
mix_leistung	8,00	46,00	57,00	59,56	80,00	100,00	553,32	23,52

Wert	Min	$Q_{0.25}$	x_{med}	\bar{x}	$Q_{0.75}$	Max	σ^2	σ
mix_macht	2,00	27,00	43,00	48,41	71,00	99,00	448,34	21,17
iqt_gesamt	1,00	76,00	87,00	83,49	94,00	99,00	180,60	13,44
iqt_merkf	0,00	52,00	76,00	75,36	93,00	99,00	534,46	23,12
iqt_logik	8,00	70,00	82,00	78,32	93,00	99,00	264,22	16,25
iqt_rechnen	10,00	78,00	87,00	80,66	92,00	99,00	334,30	18,28
iqt_technik	1,00	60,00	80,00	73,48	89,00	99,00	384,59	19,61
viq_s	-1,32	-0,41	0,44	0,39	1,30	1,30	0,82	0,91
viq_n	-1,29	-0,59	0,08	0,16	1,25	1,42	0,94	0,97
viq_t	-0,96	0,25	1,38	1,00	1,96	2,02	0,95	0,97
viq_f	-1,37	-1,15	-0,19	-0,22	0,36	1,37	0,80	0,89
viq_j	-2,08	-0,48	0,16	0,29	0,90	5,00	0,90	0,95
viq_e	-2,09	-0,10	0,65	0,37	0,89	3,67	0,69	0,83
mathe	0,00	70,00	80,00	80,89	90,00	100,00	255,89	16,00
mathe1_modul	2,00	7,10	8,90	9,31	11,90	14,00	9,17	3,03
mathe2_modul	2,00	7,10	10,10	9,16	11,90	14,00	10,50	3,24
progr_modul	2,00	8,00	10,10	10,09	11,90	14,00	6,64	2,58
mittelw	2,00	7,70	9,70	9,52	11,40	14,00	5,67	2,38

Tabelle 9.: Univariate Maßzahlen. Min: Das Minimum. $Q_{0.25}$: Das erste Quantil (25 Prozent). x_{med} : Der Median. \bar{x} : Das Arithmetische Mittel / Der Durchschnitt. $Q_{0.75}$: Das dritte Quantil (75 Prozent). Max: Das Maximum. σ^2 : Die Varianz. σ : Die Standardabweichung.

Ebenfalls beachtenswert ist das Verhältnis des Medians x_{med} im Vergleich mit dem arithmetischen Mittel \bar{x} . Weichen diese beiden Werte stark voneinander ab, ist dies ein Indikator für fehlende Kontingenz in der Datenmenge. Ist dies der Fall, sollten übrige Untersuchungen von Maßzahlen mit Skepsis durchgeführt werden, da auch dort die fehlenden Zusammenhänge einzelner Ausprägungen Aussagen erschweren. Vor allem bei den ViQ-Werten t (*Thinking*), e (*Extraversion*) und j (*Judging*) weichen Median und arithmetisches Mittel stellenweise sehr stark voneinander ab. Beim *IQt Technik* und der *IQt gesamt* fallen die Unterschiede ebenfalls groß aus. Der Median des ViQ n beträgt 0,08, das arithmetische Mittel 0,16. Dies ist selbst für standardisierte Werte auffällig. Auch die Abweichung des Medians IQt-Technik zum arithmetischen Mittel von 80 zu 73 ist auffällig groß.

Die *Varianz* ist ein Maß dafür, wie weit die quadratischen Abweichungen einer Variable von ihrem Erwartungswert im Durchschnitt entfernt liegen. Ist die Varianz hoch, streuen die Ausprägungen einer Variable stark um einen Erwartungswert. Dies deutet darauf hin, dass sich pauschale Aussagen über eine Datenmenge nur unter Vorbehalt treffen lassen. Auffällig hoch fallen die Varianzen vor allem bei den *Mix-*, sowie den *IQt-Werten* aus. Die Standardabweichung σ der *IQt-Merkfähigkeit* weicht um 23,12% ab vom Erwartungswert. Verglichen mit der Abweichung um 14,6% beim Mathematik-Durchschnitt der Oberstufe ($\sigma = 2,28$ im Intervall [1, 15]) ist dies ein hoher Wert. Der NAK-Mathematik-Test liegt mit 16% Abweichung im mittleren Feld. Diese starke Streuung deutet darauf hin, dass es bei diesen Werten zu starken Unregelmäßigkeiten unter den Probanden kommt. Vorsicht ist bei der Interpretation der Varianz jedoch dahingehend geboten, dass die Werte als Quadrate vorliegen und somit in einer anderen Einheit vorliegen als die ursprünglichen Variablenausprägungen. Häufiger wird daher die Standardabweichung betrachtet.

Unmittelbar verwandt mit der Varianz σ^2 ist die Standardabweichung, welche die Quadratwurzel der Varianz darstellt. Die Standardabweichung beschreibt die zu erwartende Abweichung einer Variablenausprägung vom Erwartungswert. Da die Standardabweichung nahe verwandt ist mit der Varianz, bleibt die Deutung bestehen, dass die *Mix-* und *IQt-Werte* auffällig stark streuen.

Die übrigen Werte des Medians sowie der Quantile unterstreichen als Lagemaße lediglich die bereits über die Extremwerte und das arithmetische Mittel getroffenen Aussagen.

4.2.8. Statistische Interpretation der bivariaten Maßzahlen

Die beschreibende univariate Statistik zeigt auf, wie isoliert betrachtete Variablen strukturiert sind. Für diese Arbeit von besonderem Interesse ist die Frage nach Zusammenhängen zwischen mehreren Variablen. Es geht um die Frage, ob anhand vorhandener Gegenwartsdaten auf zukünftige Entwicklungen geschlossen werden kann. Um dies zu ergründen, gilt es herauszufinden, ob bereits durch statistische Mittel solch eine Vorhersage getroffen werden kann. Darauf aufbauend kann anschließend untersucht werden, ob ein Expertensystem auf Basis eines Bayesschen Netzes eine genauere Aussage treffen kann. Die ermittelten Werte der bivariaten Statistik sind in Tabelle 10 gelistet.

Wert	$cov(X, Y)$	ρ	r_{xy}	χ^2	R^2
alter	-1,0440		-0,1697	0,0005	0,0288
deutsch_durchs		0,3451		0,1791	0,1176
englisch_durchs		0,3310		0,0000	0,1153
mathe_durchs	2,4463	0,4499		0,0000	0,2028
gesamt_durchs	1,9277	0,4617		0,0002	0,2152
englisch_bsc	0,0783		0,1958	0,1740	0,0383
mix_leistung	-2,5803		-0,0461	0,1197	0,0021
mix_bindung	-0,1776		-0,0039	0,7287	0,0000
mix_macht	-0,5303		-0,0105	0,9732	0,0001
iqt_gesamt	4,5041		0,1408	0,0000	0,0198
iqt_merkf	3,2188		0,0585	0,6278	0,0034
iqt_logik	5,6079		0,1449	0,1264	0,0210
iqt_rechnen	3,0375		0,0698	0,1008	0,0049
iqt_technik	1,9361		0,0415	0,5574	0,0017
viq_s	-0,0125		-0,0058	0,6815	0,0000
viq_n	-0,1850		-0,0802	0,624	0,0064
viq_t	0,1262		0,0544	0,5011	0,0030
viq_f	0,1223		0,0576	0,8638	0,0033
viq_j	-0,0710		-0,0314	0,9966	0,0010
viq_e	-0,0854		-0,0433	0,1780	0,0019
mathe	7,2180		0,1895	0,3659	0,0359

Tabelle 10.: Bivariate Maßzahlen. $cov(X, Y)$: Kovarianz. ρ : Rangkorrelationskoeffizient nach Spearman. r_{xy} : Korrelationskoeffizient nach Pearson. χ^2 : Chi-Quadrat-Unabhängigkeitstest. R^2 : Bestimmtheitsmaß

Die Kovarianz gibt Auskunft darüber, in welche Richtung die betrachteten Variablen verlaufen. Ist die Kovarianz stark positiv oder stark negativ, lohnt sich die weitere Prüfung auf eine Korrelation. Liegt die Kovarianz jedoch nahe bei 0, so gibt es keinen gemeinsamen Trend der Daten. Ein statistischer Zusammenhang ist in einem solchen Fall abwegig. Bezogen auf die vorliegenden Daten zu Studierenden der Tabelle 10 fällt auf, dass die Variablen *MIX-Bindung*, *MIX-Macht* und die *ViQ-Werte* keinen gemeinsamen Trend mit den durchschnittlichen Modulergebnissen aufzeigen. Für diese Werte ist somit auch eine Korrelation mit den Modulergebnissen unwahrscheinlich.

Sehr aufschlussreich können Korrelationskoeffizienten sein. Sie beschreiben einfach ausgedrückt, ob niedrige Werte einer Variablenausbildung mit niedrigen Werten einer anderen Variablenausbildung einhergehen (ebenso hohe Werte). Ist eine Korrelation nahe bei 1, so könnte eine gemeinsame Ursache zugrunde liegen. Bei Korrelationen ist es unerheblich, welche Variable als unabhängig und welche als abhängig angesehen wird – die Korrelation ist kommutativ. Zu beachten ist die Skalierung der vorliegenden Daten. Liegt eine Variable ordinalskaliert vor, so ist der Rangkorrelationskoeffizient nach Spearman zu nutzen. Sind alle Variablen mindestens kardinal skaliert, kann der Korrelationskoeffizient nach Pearson herangezogen werden. Es muss jedoch darauf geachtet werden, dass einer starken Korrelation nicht zwangsläufig ein echter Zusammenhang folgt. Ist eine Korrelation stark ohne echten Zusammenhang, spricht man auch von einer *Scheinkorrelation*. Die Untersuchung darf somit nicht bei einer bloßen Betrachtung des Korrelationskoeffizienten enden.

Auffällig ist, dass die Schulergebnisse insgesamt und die Mathematik-Schulergebnisse mit 0,45 und 0,46 im Vergleich stark korrelieren. Ab Werten von $r_{xy} \geq 0,5$ kann von einem linearen Zusammenhang der Werte ausgegangen werden (Schira 2012, vgl. S. 114ff). Ferner fällt auf, dass die übrigen Werte wie *MIX*, *IQt* oder *ViQ* mit $r_{xy} = -0,0105$ für *MIX-Macht* ausgesprochen schwach mit den durchschnittlichen Modulergebnissen korrelieren. Die *Mix*-Werte weisen sogar mit $r_{xy} = -0,0461$ für die *MIX-Leistung* eine Antikorrelation auf. Auch unter den *ViQ*-Werten finden sich einige Antikorrelationen. Einzig der Gesamtwert des *IQt* zeugt mit $r_{xy} = 0,1408$ von einer zwar immer noch sehr schwachen, aber nicht völlig fehlenden Korrelation.

Es kann ausgesagt werden, dass gemäß der Korrelationsanalyse zwischen den Schulergebnissen und den späteren Modulergebnissen ein Zusammenhang bestehen könnte, dies aber nicht für die psychosozialen Faktoren gilt.

Der χ^2 -Unabhängigkeitstest bewertet in einem s.g. p-Wert die Wahrscheinlichkeit, dass eine vermutet erklärte Variable in Wirklichkeit von einer erklärenden Variable unabhängig ist. Dabei unterliegen die gemessenen Daten einem α -Fehler, der in der Regel auf 5%, also $\alpha = 0,05$, festgelegt wird (Keller 2015). Übersteigt somit ein p-Wert 0,05, so wird die Nullhypothese H_0 (Variable 1 ist von Variable 2 unabhängig) nicht abgelehnt. Für alle Variablen in Tabelle 10, bei denen die Werte der χ^2 -Spalte 0,05 übersteigen, gilt: Die Modulergebnisse sind von diesen Variablen unabhängig.

Das Ergebnis zeigt auf, dass unter den erfassten Schulergebnissen die Modulergebnisse lediglich von den Deutsch-Leistungen unabhängig sind. Unter den psychosozialen Variablen *MIX*, *IQt*

und *ViQ* lässt sich dies einzig vom Gesamtergebnis des *IQt* sagen. Selbst die einzelnen Items *IQt-Merkfähigkeit*, *-Logik*, *-Rechnen* und *-Macht* erklären die Module demnach nicht. Es liegt die Vermutung nahe, dass der *IQt*-Wert unnötig aufgeteilt wurde und als Gesamtwert eine weit bessere Vorhersage der Modulergebnisse erlaubt als die Einzelwerte. Interessant hierbei ist, dass das Alter trotz einer schwachen Antikorrelation einen sehr niedrigen p-Wert aufweist und die Nullhypothese daher abgelehnt wird. Dies zeigt auch, dass der p-Wert nicht isoliert betrachtet werden sollte, sondern nur in Verbindung mit weiteren Maßzahlen.

Das Bestimmtheitsmaß R^2 drückt aus, inwieweit eine abhängige Variable von einer unabhängigen Variable erklärt werden kann. Die Werte bewegen sich im Einheitsintervall von $[0, 1]$ und sind in Prozent aufzufassen. Für die untersuchten Daten lässt sich demnach aussagen, dass von den schulischen Durchschnitts- und Mathematik-Ergebnissen je circa 18% der Modulergebnisse erklärt werden können. Der NAK-Mathematik- und -Englisch-Test erreichen jeweils lediglich 3,6%. Unter den psychosozialen Variablen lässt sich nach R^2 keine Bestimmtheit feststellen.

4.2.9. Zusammenfassung der Statistischen Interpretation und Scatterplots

Es lässt sich somit zusammenfassen, dass durch die bloße uni- oder bivariate beschreibende Statistik der vorliegenden Daten lediglich ein schwacher Zusammenhang zwischen den Schulergebnissen und den späteren Modulergebnissen erkannt werden kann. Die psychosozialen Variablen *ViQ*, *MIX* und *IQt* scheinen als Prädiktoren für eine Abschätzung des späteren Studienerfolgs wenig geeignet zu sein, wenngleich einzelne Werte wie der *IQt-Gesamtwert* einer weiterführenden Betrachtung unterzogen werden könnten.

Eine einfache und sehr aufschlussreiche Methode der Abschätzung von Zusammenhängen oder Unabhängigkeiten von Variablen bietet die Betrachtung von Scatterplots. Auf diesen werden die Ausprägungen mehrerer Variablen aufgezeichnet und betrachtet, ob die Datenverläufe auf oder um Regressionsgeraden liegen. Die Scatterplots zu den Variablen lassen vermuten, was die zuvor errechneten statistischen Maßzahlen bereits besagen: Die Schulergebnisse scheinen mit den Studienleistungen zusammenzuhängen, die psychosozialen Variablen jedoch nicht. Anschaulich macht dies der direkte Vergleich des Scatterplots in Abbildung 16 (Seite 102) für die *Oberstufenergebnisse* mit dem in Abbildung 20 (Seite 106), dem *ViQ-Thinking-zu-Modulergebnis-Plot*, sowie dem in Abbildung 19 (Seite 105), dem Scatterplot zur *MIX-Leistung*

mit den *Modulergebnissen*. In Abbildung 7 (Seite 41) ist eine Übersicht der Scatterplots mit Regressionsgeraden dargestellt.

Dem Scatterplot optisch nach zu urteilen, könnte der *IQI* unter diesen Werten am ehesten in einem Zusammenhang mit den Modulergebnissen stehen. Der statistischen Auswertung nach zu urteilen, fällt dieser Zusammenhang jedoch schwach aus.

Auffällig an den Scatterplots der *ViQ*-Werte ist die Anhäufung an den Klassensprüngen. Dort wären Klassenbetrachtungen und Intervallsabgrenzungen angebracht. So ließe sich eventuell doch ein Zusammenhang mit den fortgeschrittenen statistischen Mitteln ausmachen. Dies würde für die Frage, ob bereits mit diesen einfachen Mitteln Zusammenhänge erkannt werden können, jedoch zu weit führen und ist nicht Gegenstand dieser Untersuchung.

Vor allem die Korrelation lässt sich besonders gut abschätzen, wenn über die Scatterplots der Matrizen aus Variable zu Moduldurchschnittsergebnissen eine Regressionsgerade gelegt wird, wie es in Abbildung 7 (Seite 41) dargestellt wird. Je näher sich eine solche Regressionsgerade an eine 45°-Diagonale oder Winkelhalbierende mit positiver Steigung annähert – von der linken unteren Ecke zur rechten oberen Ecke –, desto größer ist der lineare Zusammenhang. Liegt die Gerade jedoch in einer Horizontalen, kann eine statistische Unabhängigkeit vermutet werden (was durch den χ^2 -Unabhängigkeitstest zu prüfen ist). Verläuft die Regressionsgerade negativ-winkelhalbierend, also von der linken-oberen Ecke zur rechten-unteren Ecke, dann liegt eine Antikorrelation vor. Eine Antikorrelation würde bedeuten, dass je höher die Ausprägung einer Variable ausfällt, desto niedriger ist die Ausprägung der anderen Variable. Dargestellt sind vier Scatterplots mit deren Regressionsgeraden nachfolgend in Abbildung 7. Darin bestätigt sich die Vermutung, dass die Schulergebnisse einen weit größeren linearen Zusammenhang aufweisen als z.B. die MIX-Werte.

Da die Statistik bisher nur die Schulergebnisse in Zusammenhang mit den Modulleistungen bringen konnte, wird weiter den Hypothesen aus Abschnitt 1.3 nachgegangen, ob ein Expertensystem auf Basis von Bayesschen Netzen Zusammenhänge aufzeigen kann.

4.3. Erstellung von Korrelationstabellen und deren Interpretation

Eine zentrale Frage ist, welche Verbindungen die vorhandenen Parameter untereinander haben, also welcher Parameter die Wahrscheinlichkeit eines anderen Parameters bedingt. Dabei ist das mächtigste Werkzeug die Benutzung der Echtdaten. Wo Zusammenhänge existieren, werden Muster in den Daten zu erkennen sein. Wo keine Muster sind, werden aller Wahrscheinlichkeit nach keine Zusammenhänge bestehen. Somit wird in diesem Abschnitt der Weg einer Korrelationsanalyse gewählt. Darauf aufbauend werden anschließend mögliche Verbindungen identifiziert.

4.3.1. Korrelationstabellen erstellen

Eine Korrelation zeugt von einem statistischen Zusammenhang von Parametern. Es muss sich bei einer Korrelations- oder Regressionsanalyse stets auch Gedanken über die Möglichkeit einer Scheinkorrelation gemacht werden. Eine Korrelation ist nichtsdestotrotz ein guter Hinweis auch auf bedingt abhängige Wahrscheinlichkeiten unter Variablen. Wo kaum eine oder gar keine Korrelation ermittelt werden kann, wird aller Wahrscheinlichkeit nach auch keine bedingt abhängige Wahrscheinlichkeit existieren.

Aus diesen Gründen ist ein sinnvolles Vorgehen für die Modellierung der Struktur eines Bayesschen Netzes die Ermittlung der Korrelationen. In Abbildung 8 ist dargestellt, wie dies anhand des Programms Microsoft Excel durchgeführt wurde. Jede Variable wird mit jeder anderen Variable korreliert. Im Anschluss daran wurden die stark positiven und stark negativen Werte farblich hervorgehoben. Bei der Ermittlung von Zusammenhängen ist es erst einmal irrelevant, ob eine negative bzw. Antikorrelation vorliegt oder eine positive. Beides deutet auf einen Zusammenhang hin. Zwei Ausschnitte der Korrelationstabelle befinden sich im Anhang unter Abschnitt A.5.

4.3. Erstellung von Korrelationstabellen und deren Interpretation

	alter	deutsch_du	englisch_du	mathe_durc	englisch_durc
alter	1,00	-0,20	-0,19	-0,22	0,00
deutsch_durchschnitt	-0,20	1,00	0,59	0,47	0,14
englisch_durchschnitt_abi	-0,19	0,59	1,00	0,45	0,32
mathe_durchschnitt	-0,22	0,47	0,45	1,00	0,13
englisch_durchschnitt_bsc	0,00	0,14	0,32	0,13	1,00
mix_leistung	0,07	-0,07	-0,03	0,00	0,00
mix_bindung	0,03	-0,03	-0,03	0,01	0,01
mix_macht	-0,01	0,03	0,02	-0,03	0,05
iqt_sprache	-0,05	0,09	0,09	0,10	0,20
iqt_merkfaehigkeit	0,03	0,06	-0,02	0,03	0,10

Abbildung 8.: Ausschnitt einer Korrelationstabelle zur Ermittlung der möglichen BN-Struktur.

Es fällt auf, dass entlang der Diagonale stets die Korrelation von 1 auftritt. Dies ergibt Sinn: Es werden identische Variablen miteinander korreliert. Entlang der Diagonale finden sich zudem auffallend viele stark positive und stark negative Korrelationen. Auch dies ist mit der Gleichartigkeit der Variablen zu erklären. Die Variablen sind thematisch sortiert. So stehen Abiturnoten, Modulnoten, ViQ, MIX oder IQT-Werte nahe beieinander.

4.3.2. Unmittelbare Korrelationen identifizieren

Nach Erstellung einer Korrelationstabelle, wie sie in Abbildung 8 dargestellt ist, müssen geeignete Variablen-Paare anhand ihrer Korrelation und fachlichem Wissen identifiziert werden. So weisen zwar gleichartige Variablen wie IQT-Logik und IQT-Technik eine signifikante Korrelation auf. Doch die fachliche Aussage, der eine Wert sei bedingt abhängig vom anderen Wert, ergibt wenig Sinn. Zu beachten ist jedoch, dass es nicht nur um fachliche Sinnhaftigkeit geht, sondern auch darum, welche Verbindungen sich mit den *Daten decken*. Dies wird vermutlich auch für spätere, zusätzliche Daten der Fall sein und ist somit eine wertvolle Information. Dass dies diskutabel ist, zeigt sich in den nachfolgenden Abschnitten. Diese Auswahl von Abhängigkeiten unter Parametern kommt somit aus zweierlei Gründen zustande: Zum einen wird eine hohe Korrelation betrachtet. Zum anderen werden Definitionen z.B. aus Abschnitt 2.5 zu Rate gezogen. Etwaige fachliche Zusammenhänge wurden erfasst, um sie anschließend in den Experteninterviews zu diskutieren. Dafür sind die Experteninterviews sehr gut geeignet. So benennen Scutari und Denis (2014, vgl. S. 95) neben dem algorithmischen Lernen einer BN-Struktur die Arbeit mit Experten als gut geeignetes Mittel.

4.3.3. Arc-Richtungen vermuten

Nachdem wie oben beschrieben anhand der Korrelationen und mit fachlichem Hintergrundwissen mögliche Parameter-Paare ausfindig gemacht wurden, ist die *Richtung* der Arcs oder Verbindungen zu vermuten. Wie in Abbildung 23 (Seite 109) dargestellt und im Anhang unter Abschnitt A.6 beschrieben wird, entscheidet in einem Bayesschen Netz die Richtung der Verbindungen darüber, welche bedingt abhängigen Wahrscheinlichkeiten berechnet werden können. Ist die Kausalität *falsch herum*, so wird das Netz bei Anfragen unsinnige oder fehlerhafte Ergebnisse liefern. Die Richtungsermittlung ist daher kritisch und von hoher Bedeutung.

Dafür wurden die Parameterpaare fachlich geordnet und einander gegenüber gestellt, wie in Abbildung 9 dargestellt. Dies ist gleichsam auch die Diskussionsgrundlage für die Experteninterviews, da vor allem die fachliche Expertise für die Richtungsermittlung entscheidend ist.

Aus den Definitionen in Abschnitt 2.5 lassen sich Richtungen vermuten. So darf angenommen werden, dass die Gedankenstruktur, die der MIX-Wert widerspiegelt, die Resultate eines IQ-Tests bedingen. Der IQ ist wiederum maßgeblich für die Performance von Prüfungen, wie sie z.B. Modulergebnisse oder der Mathematiktest widerspiegeln. Auf diese Weise wurden die Verbindungsrichtungen vermutet.

iqt_merkfaehigkeit	<->	mathe			0,129
iqt_rechnen	<->	englisch_durchschnitt_bsc			0,130
iqt_rechnen	<->	mathe			0,267
iqt_sprache	<->	englisch_durchschnitt			0,195
iqt_sprache	<->	mathe			0,166
iqt_technik	<->	mathe			0,207

Abbildung 9.: Auf Basis der Korrelationstabelle ermittelte Korrelationen, die als Arcs herangezogen werden können.

4.3.4. Indirekte Zusammenhänge identifizieren

Problematisch ist die Frage nach etwaigen indirekten Abhängigkeiten. So lassen sich Implikationen als Syllogismus Barbara formulieren (getreu: „Alle Menschen sind sterblich. Sokrates ist ein Mensch. Also ist Sokrates sterblich“ (Staab 2012, vgl. S. 23)), was eine indirekte Abhängigkeit vermuten lässt.

Dargestellt sind einige dieser Syllogismen in Abbildung 10. So zeigt sich, dass die Modulergebnisse kaum beeinflusst werden. Die Ergebnisse des NAK-Mathematik-Tests werden hingegen von IQT-Logik und dem IQT-Rechnen beeinflusst. Die Mathematik-Test-Ergebnisse korrelieren wiederum mit den Ergebnissen des ersten Mathematik-Moduls. Somit kann vermutet werden, dass dort ein Syllogismus vorliegt: IQT-Logik \implies Mathematik-Test \implies Mathe1-Modul.

	mathe	mathe_durchschnitt
iqt_sprache	0,17	0,10
iqt_merkfaeh	0,13	0,03
iqt_logik	0,28	0,16
iqt_rechnen	0,27	0,04
iqt_technik	0,21	0,11
viq_t	0,11	0,11
mathe	1,00	0,19
mathe1_punkt	0,19	0,41
mathe2_punkt	0,16	0,42
progr1_punkt	0,10	0,24

Abbildung 10.: Identifizierung möglicher 'Mittler', die mit Experten diskutiert werden.

Solche vermuteten Syllogismen wurden in dem anschließend erstellten BN-Modell, dargestellt in Abbildung 11, mit einem Bleistift eingezeichnet (somit nicht auf der Abbildung), um mit den Experten in Interviews diskutiert zu werden.

4.4. Modellierung durch MSBNx

Zur Visualisierung des ermittelten Bayesschen Netzes wurde das Produkt *MSBNx* genutzt. Dabei handelt es sich um ein Programm der Forschungsabteilung Microsofts zur einfachen Erstellung, Visualisierung und Erprobung von Bayesschen Netzen (Shum 2017). Dargestellt ist das erzeugte BN in Abbildung 11.

4.5. Experteninterviews

Wie durch Scutari und Denis (2014, vgl. S. 125ff) empfohlen, werden für die Erstellung von Bayesschen Netzen Lernalgorithmen genutzt, es ist jedoch in den allermeisten realen Fällen ratsam, die Details der Struktur eines Bayesschen Netzes durch Experten zu konstruieren. Selten sind Daten derart vielzählig und besitzen so deutliche Zusammenhänge, dass auf Anhieb durch einen Lernalgorithmus eine Struktur ausreichend hoher Güte entsteht. Dieser hybride Weg – zuerst Lernalgorithmen zu nutzen, um dann durch Experteninterviews die Zusammenhänge zu erarbeiten – wird auch in dieser Arbeit genutzt. Die Durchführung und die Erkenntnisse der Experteninterviews werden in diesem Abschnitt beschrieben.

4.5.1. Vorgehen

Die Kernthemen der Experteninterviews sind die Fragen danach, ob das erarbeitete Bayessche Netz der Realität entspricht und ob die vermuteten *Richtungen* der bedingten Abhängigkeiten plausibel erscheinen. Dafür wird den Experten die Grafik Abbildung 11, die das Bayessche Netz modellhaft darstellt, vorgelegt, zusammen mit den Korrelationstabellen aus Abschnitt A.5. In dem Bayes-Netz-Modell wurden die vermuteten Abhängigkeiten, die in Unterabschnitt 4.3.4 diskutiert werden, aufgezeigt. Die Auffälligkeiten, die auch in Abbildung 10 dargestellt sind, wurden den Experten erläutert und deren Bedeutung diskutiert. Ferner wurde mit den Experten besprochen, wie die Richtung der Variablen-Tupel aus Abbildung 9 zu vermuten ist. Den Experten wurde zu Beginn eines Interviews stets ein Abstract darüber gegeben, wie die uni- und bivariate Auswertung der Daten erfolgte, welches Vorgehen zum Bayesschen Netz führen soll und wie die Parameter gemäß Abschnitt 2.5 zu verstehen sind.

Das Interview erfolgte frei und Leitfaden-getrieben. Fragen wurden vorformuliert, mussten aber nicht explizit oder auf eine vorgefertigte Weise beantwortet werden. Der Leitfaden befindet sich in Abschnitt A.8. Wörtliche Mitschriften wurden nicht angefertigt, da es sich bei den Interviews nicht um eine quantitative Erhebung handelt. Stattdessen werden nachfolgend die wichtigsten Ergebnisse zusammengefasst. Einige Experten äußerten den Wunsch, anonym zu bleiben. Aus diesem Grunde werden die entsprechenden Transkripte dieser Arbeit anonymisiert zur Verfügung gestellt. Die neun befragten Experten weisen allesamt Verbindungen zur Studieneignungsdiagnostik, zur Informationstechnologie oder beidem auf. So befinden sich unter den Interview-Partnern Professoren und Studiengangsleiter von informationstechnologischen oder psychologischen Studiengängen, Personalverantwortliche aus der Wirtschaft, Projektleiter oder

Wissenschaftler im Bereich der Studieneignungsdiagnostik oder KI. Somit sind alle befragten Experten in der Lage, die zur Diskussion gestellten Themen qualifiziert zu beantworten.

4.5.2. Evaluation ausgewählter Module als Eignungsindikatoren

Den Interviewpartnern wurde die Tabelle 5 gezeigt, welche die Modulauswahl zur statischen Voruntersuchung darstellt. Dazu wurden die Modulbeschreibungen entsprechend Abschnitt A.10 auszugsweise zitiert. Auf die Frage, ob die ausgewählten Module als repräsentativ für die grundlegende Eignung eines Softwareentwicklers verstanden werden kann, haben sich viele Interviewpartner positiv geäußert. Allerdings erfolgte eine Aufklärung darüber, dass unter den ursprünglichen Programmier-Modulen je zwei Hausarbeiten und je zwei Klausuren die Prüfleistung darstellen. Dies ist somit ein schlechter Vergleich. Daher wurde umgeschwenkt und statt Programmierung 1 das Modul Programmierung 2 der Studiengänge Wirtschaftsinformatik und Angewandte Informatik für die Erarbeitung des Bayesschen Nestzes genutzt. Die Qualifikations- und Modulziele dazu aus Abschnitt A.10 zeigen jedoch, dass die Ziele von Programmierung 1 und Programmierung 2 sehr ähnlich sind. Dort heißt es zu den Qualifikationszielen für Programmierung 2: „Kenntnisse und Fertigkeiten, Problemlösungen algorithmisch zu formulieren“. Somit eignet sich auch dieses Modul für die Untersuchung. Die für das BN genutzten Modelle sind in Tabelle 11 aufgeführt. Dabei wurde von Experten angegeben, dass für die Vergleichbarkeit unterschiedlicher Module eine z-Standardisierung (beschrieben in Abschnitt 4.2) notwendig sei. Dies wurde für die Untersuchung des Bayesschen Netzes zuvor getan. Fehlende Werte deuten dabei auf einen Abbruch des Studiums oder das Verschieben einer Klausur hin. Beides wurde mit dem Resultat der Note 5 übersetzt.

Studiengang	Mathemodul 1	Mathemodul 2	Softwaremodul
BWL	Wirtschaftsmathe 1	Wirtschaftsmathe 2	Einführung EDV
WInf	Diskrete Mathe. 1	Diskrete Mathe. 2	Program. 2
WIng	Ingenieursmathe	Wirtschaftsmathe	Einf. Softwareentw.
AInf	Diskrete Mathe. 1	Diskrete Mathe. 2	Program. 2

Tabelle 11.: Auswahl geeigneter Module als Leistungsindikatoren des logischen Denkvermögens. **BWL**: B.Sc. Betriebswirtschaftslehre. **WInf**: B.Sc. Wirtschaftsinformatik. **WIng**: B.Sc. Wirtschaftsingenieurwesen. **AInf**: B.Sc. Angewandte Informatik, erstellt anhand von Modulzielen aus den Modulbüchern in Abschnitt A.10 (2016).

4.5.3. Diskussion der Arc-Richtungen

Durch die Korrelationstabellen (zwei Ausschnitte sind dargestellt in Abschnitt A.5) ließ sich feststellen, welche Variablen mit welchen in Verbindung stehen. Unklar bleibt durch diese Methode allerdings, in welche Richtung diese Abhängigkeiten gehen. Vor allem Abhängigkeiten zwischen IQt-, ViQ- und MIX-Werten waren fraglich. Demnach sei der IQ weitestgehend genetisch, ließe sich allerdings zudem bis zu einem gewissen Grad trainieren. Das Verhältnis beläuft sich dabei auf je 50 Prozent. Bei IQ-Testverfahren seien ein rasches Problemerkennungs- und die Fähigkeit zur Ableitung von Lösungsstrategien wichtige Kompetenzen. Die Experten gaben an, dass wenn eine Problemvariante bereits im Vorfeld von Probanden erlebt worden sei, die Notwendigkeit einer schnellen Adaption wegfiel. Vor allem bei jungen Studierenden ist es aber unwahrscheinlich, dass die IQ-Testverfahren durch Gewöhnungseffekte erlernt wurden. Der ViQ lässt sich ein wenig beeinflussen, ist aber weitgehend unveränderlich. Die MIX-Dimensionen hingegen lassen sich gezielt verändern und sind somit als bedingt abhängig vom ViQ und IQt zu sehen. Letztlich ergab sich eine Reihenfolge gemäß: $IQt \rightarrow ViQ \rightarrow MIX$.

4.5.4. Hinweise zur Aussparung oder Hinzunahme von Parametern

Insgesamt sahen alle Experten die Auswahl der Parameter als Durchmischung von Prüfungsergebnissen wie dem IQt und Ego-Involvement-Indikatoren wie dem MIX oder ViQ als sehr sinnvoll an.

Das Alter wurde als irrelevant oder gar störend empfunden, weshalb es herausgelassen wurde. Das Geschlecht ergibt nach einigen Interpretationen als Bedingung der Modulergebnisse Sinn, sollte aber zumindest hinterfragt werden. Die Korrelation des Alters zu Mathematik-Ergebnissen könnte z.B. mit der Lebenserfahrung zusammenhängen, sollte aber nicht pauschal als richtig erachtet werden. Auch erscheint es möglich, dass Frauen, die sich für ein technisches Studium entscheiden, dies aus Gründen der starken Überzeugung oder aufgrund von deutlichen Talenten in mathematisch-technischen Fragen tun. Es sollte den Experten nach nicht pauschal davon ausgegangen werden, dass das Geschlecht der Anwärter mit den späteren Ergebnissen in Verbindung gebracht werden kann.

4.5.5. Evaluation des Modell-Netzes

Insgesamt wurde das Modell als tauglich erachtet. Vor allem die ursprüngliche Struktur durch die Korrelationstabellen wurde als sinnvolles Vorgehen angesehen. Die so „aus den Daten“ entstandene Struktur entsprach dem, was Experten intuitiv an Verbindungen vermutet hätten. Ausnahmen sind die genauen bedingten Abhängigkeiten zwischen IQ_t, MIX und ViQ, die mit der Frage zur Arc-Richtung in Unterabschnitt 4.5.3 ergründet wurden. Das Geschlecht ergibt nach einigen Interpretationen als Bedingung der Modulergebnisse Sinn, sollte aber zumindest hinterfragt werden.

4.5.6. Diskussion der indirekten Zusammenhänge

Vor allem Wissenschaftler auf dem Gebiet der Informatik unterstrichen die Vermutung, dass es sich bei den *Mittler*-Variablen, also jenen, bei denen ein Arc hinein und ein Arc hinaus zu einer anderen Variable führt, um Störfaktoren handelt. Diese Arcs könnten direkt auf die nachfolgenden Parameter zeigen. Dies ist damit begründet, dass die Einflussfaktoren auf diese Mittler nur von den Vorgänger alleine stammen und somit keine verändernden Inferenzen vorliegen. Es wurde empfohlen, sich dennoch die Effekte von Veränderungen vor Augen zu führen und diese qualifiziert zu interpretieren. Die Gesprächstranskripte befinden sich auf dem Datenträger der Anlagen unter Anhang B.

4.5.7. Auswahl von Testdatensätzen

Die Experten insbesondere aus den Bereichen Projektmanagement und Softwaretests waren der Ansicht, dass es sinnvoll ist, Repräsentationsklassen zu bilden. Die Auswahl von 12 Datensätzen wurde zumeist als sinnvoll erachtet. Es kam dazu der Hinweis, dass bei circa 1.000 Datensätzen mindestens 5 Prozent als Testdaten genutzt werden sollten (also 50 Datensätze), um Zufälligkeiten auszuschließen. Da sich dies aufgrund der kleinen Datenbasis als nicht sinnvoll erwies, wird in Abschnitt 5.3 weiter aufgeführt.

4.6. Manuelle Struktur und Parameterlernen durch R und bnlearn

Nach Evaluierung des BNs durch Experten wird das BN erstellt und anschließend iterativ verbessert. Zur Erzeugung des entwickelten Bayesschen Netzes wird die freie Programmiersprache und gleichsam Entwicklungsumgebung *R* unter der Projektleitung von Urbanek und Plummer (2017) genutzt. Die Quelloffenheit und Modularisierung der statistischen Software hat es ermöglicht, dass zahlreiche freie Zusatzpakete und Bibliotheken erstellt wurden. Ein Zusatzpaket nennt sich *bnlearn*. Dieses Paket kann als de facto Standard in der angewandten Forschung zu Bayesschen Netzen angesehen werden (Scutari und Denis 2014, vgl. S. 125ff). Das komplette Skript zur Erzeugung des Bayesschen Netzes befindet sich im Anhang unter Unterabschnitt A.7.1. Das Resultat aus dem Befehl zum Plotten des Netzes ist dargestellt in Abbildung 13. Die einzelnen Schritte zur Erzeugung eines solchen Bayesschen Netzes werden nachfolgend beschrieben und resultieren in einem exemplarischen Vorgehensmodell.

4.6.1. Datenaufbereitung und Klassifizierung

Die Daten liegen tabellarisch vor. Dabei identifiziert eine Kopfzeile den Inhalt der darunterliegenden Daten. In Abschnitt 4.2 befindet sich eine detaillierte Voruntersuchung der Datenbasis mit Beschreibungen der einzelnen Werte. Diese liegen in unterschiedlichen Formaten vor. Einige Werte sind z-standardisiert und können somit negative Werte annehmen. Andere liegen in ganzzahligen Prozentwerten als Dezimal-Prozente im Intervall $[0, 1]$ vor. Einige Werte werden als String bzw. Zeichenkette dargestellt.

Während der Experteninterviews wurde deutlich, dass die Modulauswahl – mit Ausnahme von Programmierung 1 – geeignet sei. Daneben wurde klar, dass die Noten jedes Manipels (d.h. Jahrgang) z-standardisiert werden sollten, wie es in Abschnitt 4.2 beschrieben ist. Pro Zenturie (d.h. Klassenverbund) wären die Daten leichter zu verwenden. Die Rohdaten liegen hier nur als Manipel vor. Erst nach z-Standardisierung sollten die einzelnen Datensätze zu einem einzigen Datensatz aggregiert werden. Das Paket *bnlearn* erwartet die Eingaben als Daten-Frame. Ein Daten-Frame als R-Datenstruktur ist eine Liste gleichlanger Vektoren. Für die Arbeit mit *bnlearn* empfiehlt sich zudem eine Gleichartigkeit der sich in den Vektoren befindlichen Variablen. Im vorliegenden Fall wurde der Weg gewählt, alle Daten zu Werten mit zwei Dezimalstellen (z.B. 10.00) zu konvertieren. Einige String-Variablen wurden, u.a.

fachlich motiviert, entfernt, darunter befindet sich der zugrundeliegende Studiengang.

Die unterschiedlichen Werte, die Variablen eines Parameters annehmen können, bestimmen die einzelnen *Klassen* der späteren bedingten Abhängigkeiten. Liegen nun Parameter mit enorm vielen Ausprägungen vor – ganzzahlige Prozente können beispielsweise einhundert unterschiedliche Ausprägungen annehmen –, so werden Abfragen an das Netz enorm erschwert. Bei analogen Werten kann es unzählbar viele Werte und somit Klassen geben. Aus diesem Grunde wird von Scutari und Denis (2014, vgl. S. 144) empfohlen, Daten zu *diskretisieren*, sie also in endliche, zählbare Klassen einzustufen. Dies kann R durch den Befehl *discretize()* geschehen, wie es im nachfolgenden Code-Listing gezeigt wird:

```
1 library(bnlearn)
2 data <- read.csv("r_data_3.csv", header = TRUE,
3 + sep = ";", na.strings=c("", "NA", " "))
4 data <- data[complete.cases(data),]
5 bn_df <- data.frame(data)
6 discretize(bn_df, method = "interval", ordered = FALSE,
7   debug = FALSE)
7 res <- hc(bn_df)
```

In dem Code-Beispiel wird zuerst das Paket *bnlearn* geladen. Die Daten werden aus einer CSV-Datei eingelesen. Diese besitzt eine beschreibende Kopfzeile und den Separator ; (Semikolon). Ferner wird festgelegt, welche Zeichen oder Zeichenketten als s.g. *Null-Werte*, also nicht existente Werte, verstanden werden können.

Der Befehl in Zeile 4 sorgt dafür, dass im Objekt *data* nur all jene Datensätze hinterlegt werden, die auch als vollständig, also ohne Null-Werte, verstanden werden können. Dies ist wichtig, um den Lernalgorithmen die Ermittlung sinnvoller Ergebnisse zu ermöglichen. Zuletzt wird in Zeile 5 das eingelesene Daten-Set zu einem Daten-Frame konvertiert. Um die Daten zu bereinigen, wird die Methode *discretize()* empfohlen, die in Zeile 6 des Code-Listings angewendet wird. Dabei werden die Daten aus dem Daten-Frame klassifiziert und so diskretisiert, d.h. in eine diskrete oder zählbare Menge an Intervall-Klassen eingeordnet. Dies erleichtert die spätere Arbeit mit dem Netz massiv und behält aufgrund des Algorithmus' die Dateninformationen weitestgehend bei. Es werden lediglich sehr kleine Ungenauigkeiten in Nachkommastellen korrigiert. In Zeile 7 erfolgt anschließend der Algorithmus Max-Min Hill-Climbing (MMHC).

4.6.2. MMHC und Arc-Konstruktion

Nachdem die Daten aufbereitet wurden, erfolgt die Konstruktion der Graphen-Struktur des BN. Das Paket *bnlearn* ermöglicht es, sowohl für die Struktur als auch die bedingt unabhängigen Wahrscheinlichkeitstabellen Lernalgorithmen oder die händische Adjustierung zu nutzen. Nach Scutari und Denis (2014, vgl. S. 95) wird häufig eine Kombination aus algorithmischem Lernen und händischer Adjustierung auf Basis von Experteninterviews gewählt. Dieser Ansatz wird auch für diese Untersuchung verfolgt.

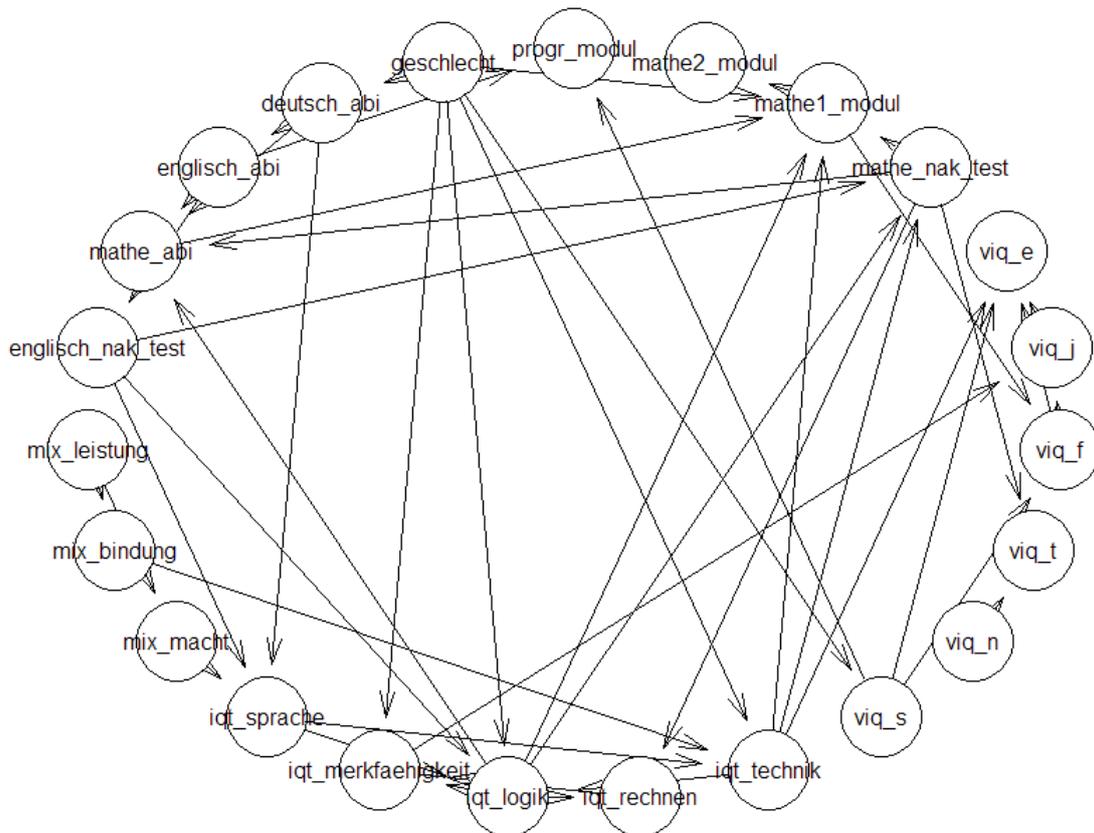


Abbildung 12.: Durch den MMHC erlernte BN-Struktur.

Der in Abschnitt 3.5 vorgestellte Algorithmus Max-Min Hill-Climbing wird in Zeile 7 des Code-Listing im letzten Abschnitt (Befehl `res ← hc(bn_df)`) genutzt, um die Struktur zu lernen. Die Struktur besteht aus den Parametern, deren Verbindungen und die Richtung der Verbindungen. Das Resultat dieses Vorgangs ist dargestellt in Abbildung 12. Der Algorithmus hat alle Parameter erfasst und diese kreisförmig angeordnet. Ferner wurden zahlreiche Verbindungen

und deren Richtungen rein aus den Daten erlernt. Somit kann gesagt werden, dass unter den verbundenen Variablen in jedem Fall eine Verbindung existieren muss. Diese sind allerdings gelegentlich unsinnig oder verfügen über Verbindungen mit verkehrter Richtung. So ist bekannt, dass der IQ genetisch erworben wurde und weitestgehend unveränderlich ist. Sollte also eine Variable diesen IQ *bedingen*, ergibt dies keinen Sinn. Vermutlich ist in dem Fall die Richtung der Bedingung falsch herum und bedarf einer Korrektur. Um diese fachlichen Fehler ausfindig zu machen, wurden die Experteninterviews durchgeführt.

Händisch angepasst werden kann das Resultat folgendermaßen:

```
1 res <- reverse.arc(res, "mathe1_modul", "viq_f")
2 res <- drop.arc(res, "englisch_nak_test", "iqt_logik")
3 plot(res)
```

In der ersten Zeile wird ein Arc umgedreht. Wie bereits im Zuge der Korrelationstabellen erklärt, deutet auch die vom MMHC ermittelte BN-Struktur deutlich darauf hin, wo es unter den Parametern den Daten nach zu urteilen Zusammenhänge gibt. Nach den Experteninterviews hat sich herausgestellt, dass z.B. die bedingte Abhängigkeit in der Reihenfolge IQt → ViQ → MIX gilt. MIX ist laut aktuellem Stand der Psychologie veränderlich. Der IQ (ebenso IQt) ist es den Experten nach nicht. In Zeile 2 wird eine Verbindung entfernt, da das bloße Umdrehen einen Zyklus erzeugen würde. Der Definition nach ist ein Bayessches Netz ein gerichteter azyklischer Graph. Die vollständige Operation befindet sich in Unterabschnitt A.7.1. Eine alternative Art, eine BN-Struktur zu erzeugen, ist die komplette Neudefinition aller Arcs. Dies ist in Unterabschnitt A.7.2 dargestellt. Die Neudefinition wird in dieser Arbeit nicht behandelt.

4.6.3. EM-Algorithmus zur Erlernung der CPT

Nachdem die Struktur des Bayesschen Netzes zuerst erlernt und dann händisch angepasst wurde, werden nun die CPT ermittelt, also die Wahrscheinlichkeitstabellen je Variable. Dafür wird der in Abschnitt 3.5 vorgestellte Expectation-Maximization-Algorithmus (EM) genutzt. Die Funktion wird auch *Fitness-Funktion* genannt, da das Netz *trainiert* wird. Diese Funktion anzuwenden ist nach der Vorarbeit in *bnlearn* durch den folgenden Befehl möglich:

```
fittedbn ← bn.fit(res, data = bn.df)
```

Damit werden die bedingt abhängigen Wahrscheinlichkeiten erlernt. Somit ist das Bayessche Netz funktionstüchtig und kann für gezielte Abfragen genutzt werden. Die Besonderheit des Netzes ist, dass es nicht starr und unveränderlich ist. Je nachdem, wie stark Verbindungen

tatsächlich sind, ob die Ergebnisse Sinn ergeben oder ob neue Erkenntnisse hinzu kommen, lassen sich alle Verbindungen, Parameter und CPTs auch im Nachhinein anpassen. Ferner können für das Netz stets von Neuem Strukturen oder CPTs erlernt oder verändert werden. Diese Veränderbarkeit, die Inferenz-Abfrage und Kompaktheit der Datenstruktur macht Bayessche Netze als Expertensysteme wertvoll. Nun ist noch zu untersuchen, wie *gut* das Netz funktioniert, um ggf. iterative Verbesserungen vorzunehmen.

Die genauen Wahrscheinlichkeiten und vor allem die bedingten Abhängigkeiten eines Knotens lassen sich folgendermaßen ermitteln:

```
1 > print(fittedbn$iqt_logik)
2 Parameters of node iqt_logik (Gaussian distribution)
3 Conditional density: iqt_logik | geschlecht +
4 engl_durchschn + iqt_sprache + iqt_technik
5 Coefficients: (Intercept)                geschlecht
6                39.5484603                -3.1814637
7
8                englisch_durchschnitt.1
9                8.8688229
10
11                iqt_sprache                iqt_technik
12                0.2167645                0.2541113
13 Standard deviation of the residuals: 14.30764
```

Die erste Zeile zeigt den Befehl zur Untersuchung eines Knotens. *fittedbn* ist das Daten-Set, getrennt durch ein Dollar-Symbol folgt der Name des Knotens. Die Ausgabe darunter gibt an, welcher Distribution oder Verteilung der Knoten folgt – in diesem Fall eine Gaussche-Normalverteilung.

Für das Verständnis der bedingt abhängige Wahrscheinlichkeiten sind die Zeilen 3 und 4 sehr aufschlussreich. Sie geben an, dass die Wahrscheinlichkeit des Knotens *iqt_logik* bedingt abhängig ist von allen Knoten, die nach dem Pipe-Symbol (|) aufgelistet werden. Die Koeffizienten geben an, welche Eltern-Knoten sich auf *iqt_logik* wie stark auswirken, sofern diese wahr sind. Dabei ist besonders zu beachten, dass sich darunter auch Knoten befinden können, die Großeltern-Knoten sind, also die Eltern-Knoten der Eltern-Knoten von *iqt_logik* sind. Somit wird deutlich, dass die Zusammenhänge in einem Bayesschen Netz sehr komplex und intransparent sein können. Die letzte Zeile gibt an, wie hoch die Standardabweichung der Residuen, also der Abweichungen von einer Näherungslösung durch alle einflussnehmenden Knoten, ist.

5. Empirische Erprobung und Ergebnisanalyse

Dieses Kapitel befasst sich mit der Nutzung des modelhaften Expertensystems, das in Kapitel 4 entwickelt wurde. Zunächst wird dafür die Qualität des Netzes in Verbindung mit den Realdaten geprüft und das Netz ggf. weiter variiert. Anschließend finden Befragungen des Netzes anhand von Testdaten statt. Die Ergebnisse und deren Güte werden den Aussagen der bivariaten Statistik gegenübergestellt.

5.1. Iterative Verbesserung

Anders als die Statistik, die als mathematische Funktion ohne *inneren Zustand* aufgefasst werden kann, sind Bayessche Netze tiefgreifend analysier-, und veränderbar. Häufig wird das erste modellhafte Netz nicht für den realen Einsatz genutzt, sondern iterativ verbessert. Zwei wichtige Methoden des Pakets *bnlearn* sind dabei *arc.strength()* und *score()*. Beide Methoden bieten Beurteilungen der Verbindungen und Netzstruktur an, womit sukzessive Anpassungen vorgenommen werden können.

Es wurden drei Methoden vorgestellt, um die Struktur eines Netzes zu erzeugen: Rein algorithmisch durch den MMHC, manuell durch z.B. Korrelationstabellen oder als Hybrid. Alle drei Ansätze wurden genutzt, um je ein Netz zu erstellen. Diese können anhand der beiden vorgestellten Methoden analysiert werden, um gute Arcs oder Verbindungen ausfindig zu machen und so das letztendliche Netz zu verbessern.

5.1.1. Arc-Strength

Durch die Methode *arc.strength(bn, data)* lässt sich eine Auflistung der Verbindungsstärken ermitteln. Es wird dabei die Stärke der probabilistischen Relationen ermittelt, welche die

Verbindungen (Arc) des Bayesschen Netzes beschreiben. Es geht also um den „Einklang“ der Verbindungen mit den tatsächlichen Daten.

Die Stärke der Verbindungen variiert je Netz stark. Die höchste Güte der Verbindungen weist das manuelle Netz auf. Da es auf Korrelationstabellen basiert, wurden nur besonders starke Zusammenhänge ausfindig gemacht. Aus diesem Grund mehren sich bei dem manuell erstelltem Netz mit 29 Arcs Werte von +5 (*geschlecht* → *programmierung_modul*) bis -19 (*iqt_rechnen* → *mathe_nak_test*). Bei dem MMHC-BN entstanden 46 Übergänge, bei denen die stärksten mit circa 0 (*viq_n* → *mathe1_modul*) und die schwächsten mit -283 (*deutsch_abi* → *englisch_abi*) ausfielen. Bei dem Hybriden entstanden 50 Arcs mit der Spannweite von +10 (*geschlecht* → *programmierung_modul*) bis -283 (*deutsch_abi* → *englisch_abi*).

5.1.2. Score

Wie für das Maschinenlernen typisch, gibt es Belohnungs- und Bestrafungsroutinen. Schlechte Verbindungen werden im Score *bestraft*, während Gute *belohnt* werden. Die Scores werden zunächst in den drei unterschiedlichen Netzen (MMHC, manuell, hybrid) betrachtet. Das Ergebnis ist wenig überraschend: Mit -59780.69 schneidet das MMHC-BN am besten ab, gefolgt vom hybriden BN mit -59811.15 und schließlich dem manuellen BN mit leicht schlechterem Score von -61400.69 . Dies liegt darin begründet, dass der MMHC-Algorithmus auf die besten Arc-Werte und somit den besten Gesamt-Score abzielt. Allerdings müssen die Verbindungen aus dem MMHC weder der Realität entsprechen (wenn z.B. der Mathematik-Test den IQ bedingt), noch bedeuten besonders viele Verbindungen eine höhere Güte der späteren Abfragen.

5.2. Bestes Bayessches Netz

Weitere Veränderungen der Übergänge bei dem hybriden Bayesschen Netz hätten zur Folge, dass sich der Score weiter verschlechtert. Ferner ist der Score des Hybrids nur wenig schlechter als der des für die Daten idealisierten MMHC-BN. Aus diesen Gründen wird das hybride Bayessche Netz für die Untersuchung ausgewählt. In diesem Kapitel sollen einige Eigenschaften aufgezeigt werden.

In Abbildung 13 ist die Struktur des hybriden BNs dargestellt. Auffällig daran ist, dass viele

der geordneten Parameter Verbindungen „zur Seite“, also zu ähnlichen Parametern aufweisen. Diese fachlich scheinbar unsinnigen Verbindungen werden hier bestehen gelassen, da sie tatsächliche Sachverhalte der Daten repräsentieren. So z.B. geht ein hoher IQt-Rechnen-Wert mit einem hohen IQt-Logik-Wert einher. Aus den Experteninterviews ging hervor, dass vor allem KI-Wissenschaftler dazu raten, solche Verbindungen bestehen zu lassen, da sie die tatsächliche Datenstruktur widerspiegeln. Ferner vereint der Nordakademie-Mathematik-Test viele Verbindungen in sich. In diesem Kontext sind die Verbindungen relativ ausgewogen und ergeben gemäß den Experteninterviews Sinn.

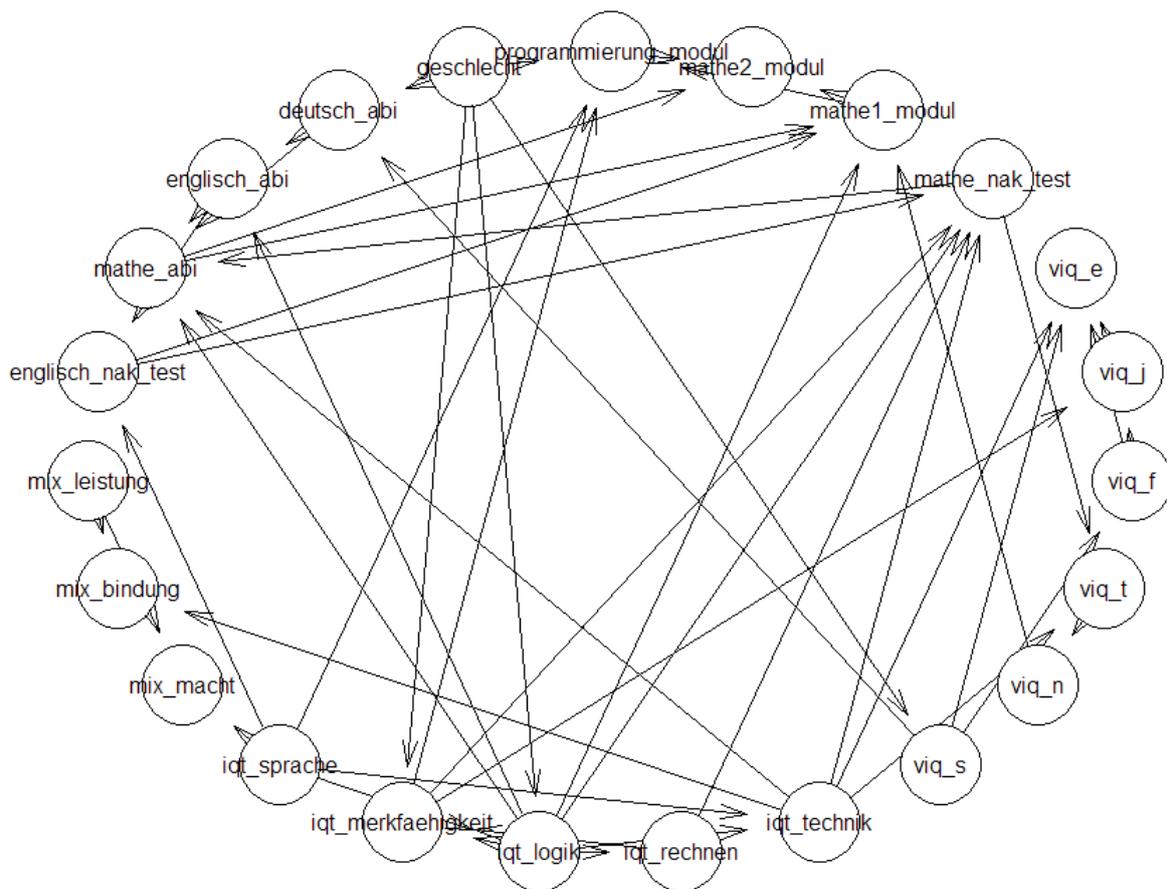


Abbildung 13.: Struktur des hybriden BNs

In Abbildung 14 sind die Verbindungsstärken als Schema dargestellt. Zur besseren Lesbarkeit wurden die Parameter durchnummeriert. In Abschnitt A.9 wird das hybride BN im Detail vorgestellt mit vollständiger Knoten-Legende. Die entscheidende Arc-Stärke verläuft vor allem von den Knoten 9 (*iqt_logik*) und Knoten 23 (*iqt_technik*), über 7 (*mathe_nak_test*) hin zu 15 (*mathe_abi*), 16 und 17 (*viq_1* und *viq_n*), sowie zu den Modulen 18 (*mathe1_modul*), 19 (*programmierung_modul*) und 20 (*mathe2_modul*). Diese Grafik gibt Aufschluss darüber, welche Variablen bei der Befragung eher berücksichtigt werden sollten. „Starke Verbindungen“ versprechen eine bessere Aussage als sehr schwache. Ein Augenmerk kann darauf gelegt werden, dass der Mathe-Modul-Knoten 18 die anderen beiden Modul-Knoten bedingt (19 und 20). Dieser ist somit ein guter Indikator für Abfragen.

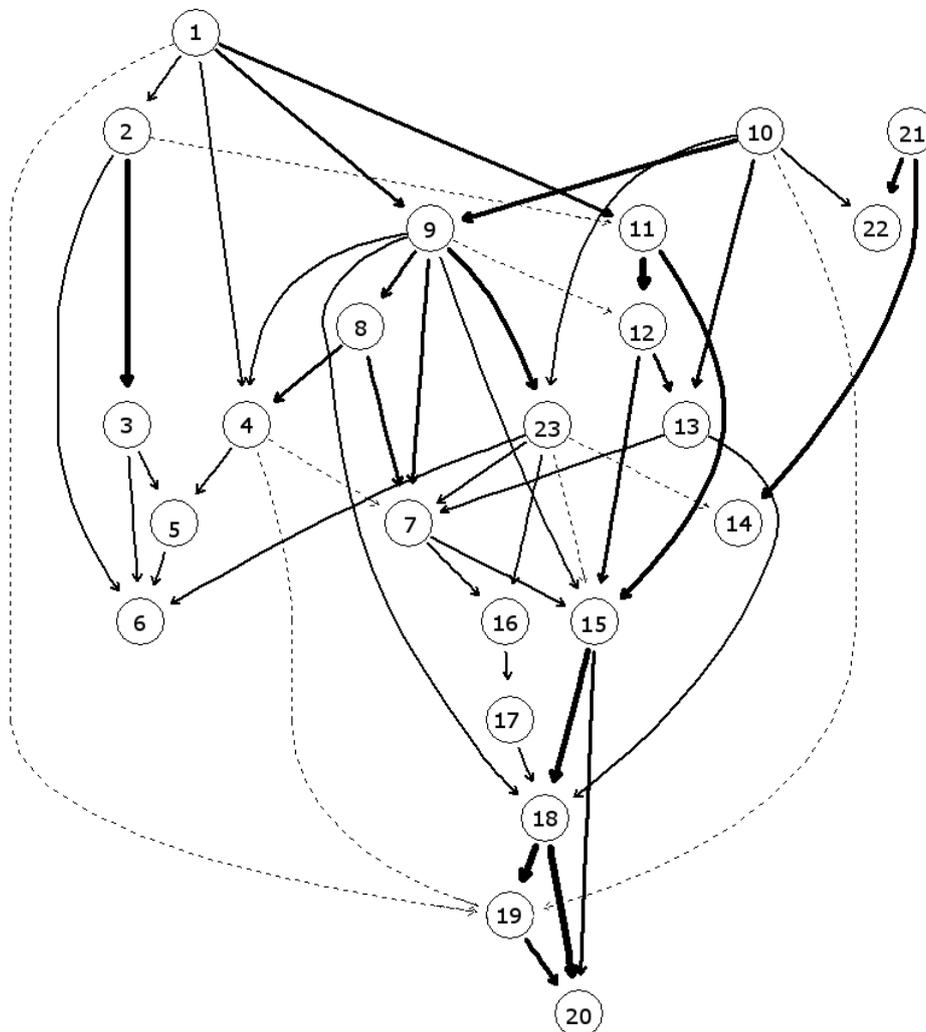


Abbildung 14.: Stärke der Arcs als Schema.

5.3. Befragung anhand von Testdaten

Das in Abschnitt 5.2 vorgestellte BN wird nun anhand von ausgewählten Testdaten überprüft und mit der bivariaten Statistik verglichen. Wichtig ist vor allem, dass die Fitness-Funktion zum Erlernen der bedingt abhängigen Wahrscheinlichkeiten ohne Testdaten erfolgen muss. Sind Testdaten in den Trainingsdaten eines BNs, wird die Suche nach Datenzusammenhängen durch das Vorhandensein der Testdaten verfälscht.

5.3.1. Testdatensätze

Nach Zuk, Margel und Domany (2012) sind für ein stabiles BN mindestens 2.000 Datensätze notwendig. Bei circa 1.000 Datensätzen als Fitness-Set können sinnvolle Aussagen ermittelt werden, sofern Aussagen des Expertensystems kritischen Analysen unterzogen werden. Für die Untersuchung wurden vier Datensätze als Repräsentanten von Testklassen ausgewählt. Es werden Kombinationen von Schulnoten zu Modulnoten einem Test unterzogen. Um sicherzustellen, dass die Testdaten repräsentativ sind, wurden dafür aus 12 Datensätzen – je drei einer Repräsentationsklasse – vier Repräsentanten ausgewählt. Die 12 für den Vergleich herangezogenen Testdaten befinden sich in Abschnitt A.3.

Die vier für die Untersuchung genutzten Datensätze weisen folgende Noten-Kombinationen auf: Ein Datensatz weist hohe Abitur- sowie Modulergebnisse auf, ein weiterer niedrige Abitur- sowie Modulergebnisse. Zwei Datensätze weisen niedrige Abitur- bei hohen Modulergebnissen auf und anders herum. Die reduzierten Daten der Tabelle 12 verdeutlichen dieses Schema. Die Modulergebnisse wurden zuvor z-standardisiert. Negative z-Werte stellen höhere Modulergebnisse dar.

#	<i>deu. abi</i>	<i>engl. abi</i>	<i>mathe abi</i>	<i>mathe1</i>	<i>mathe2</i>	<i>progr.</i>	Abi	NAK
1	10,75	11,50	14,00	-1,99	-1,51	-0,93	h	h
4	13,00	11,00	15,00	-0,14	0,38	0,88	h	l
8	12,75	9,75	8,50	-1,70	-1,52	-0,26	l	h
11	6,50	5,00	7,50	2,20	2,23	0,36	l	l

Tabelle 12.: Notenschema ausgewählter Testdatensätze

5.3.2. Ergebnisse der Netzwerkbefragung

Wichtig ist zu ergründen, mit welchen Parametern ein BN befragt wird und welche Rechnungen dahinter stehen. Das Schaubild Abbildung 14 macht deutlich, welche Parameter auf die Modulergebnisse Einfluss haben. Es zeigt sich, dass *viq_t*, *viq_n*, *mathe_abi*, *iqt_logik*, *iqt_technik*, *deutsch_abi*, *nak_mathe_test* und *nak_mathe_test* wichtig sind. Andere Parameter wie die übrigen ViQ- und MIX-Werte oder das Geschlecht spielen hingegen demnach keine Rolle.

Bei Bayesschen Netzen werden in den Rechnungen alle nicht genannten Variablen in beiden Ausprägungen *wahr* und *nicht-wahr* berechnet. Dies entspringt der Wahrscheinlichkeitslehre (aufgeführt in Abschnitt 3.2), bei der alle möglichen „Welten“ summiert werden, in denen eine Aussage wahr sein könnte. Das heißt auch: Nicht genannt bedeutet alle Welten, in denen die Aussage stimmt, und alle Welten, in denen sie nicht stimmt. Daher ist es auch hier sinnvoll, nur die Parameter explizit bei der Frage zu nennen, die einen Einfluss ausüben.

Erfragt wird in diesen Beispielen die Note des ersten Mathematik-Moduls, da es nach Abbildung 14 als Parameter die übrigen Modulergebnisse bedingt. Das ist zwar fachlich wenig sinnvoll, spiegelt aber wider, dass, den Daten nach, diese Modulnote in starkem Zusammenhang mit den übrigen Modulergebnissen steht. Sie ist also als Prüfgröße nutzbar.

Zu beachten ist die Arbeitsweise dieses BNs: Es wird nicht *exakt* nach der Höhe einzelner Parameter gefragt, sondern lediglich nach dem Durchschnitt. So wird das Netz in dieser Arbeit dahingehend befragt, ob ein Studieninteressierter Chancen auf überdurchschnittliche Modulergebnisse hat, wenn die Oberstufen-Mathematik-Ergebnisse, IQT-Logik, ViQ-n etc. unterdurchschnittlich bewertet wurden.

Der Grund für diese sehr unspezifische und undifferenzierte Art der Fragen ist, dass das Netz logische Aussagen prüft und nicht die Klassenzugehörigkeit. Die Daten zu den NAK-Studierenden sind kontinuierlich und nicht diskret. Soll heißen: Wären die Daten zuvor in weite Klassen eingeordnet worden, wie z.B. Oberstufen-Ergebnisse über- und unter 10 Punkten, dann hätte man das Netz nach „Klassenzugehörigkeit“ fragen können. Da die Daten kontinuierlich sind, ist somit eher nach „besser als 10 Punkte“ oder „schlechter als IQT-Logik von 80 Prozent“ zu fragen.

Gefragt wird stets danach, ob der Studierende eine Chance auf überdurchschnittliche Ergebnisse hat, d.h. Modulergebnisse kleiner 0, da diese z-standardisiert sind und niedrigere Werte höhere Resultate bedeuten.

Repräsentantenklasse: Hohe Schulnoten, hohe Modulnoten (1)

```
1 > cpquery(fittedbn, event = (mathe1_modul < 0 ), evidence =
2 + (mathe_abi >= 12 & viq_t > 1 & viq_n > 0 &
3 + iqt_logik > 90 & iqt_technik > 90 &
4 + mathe_nak_test > 80), n=1000000 )
5 [1] 0.7654321
6
7 > cpquery(fittedbn, event = (mathe1_modul < 0 ), evidence =
8 + ( viq_t > 1 & viq_n > 0 &
9 + iqt_logik > 90 & iqt_technik > 90 &
10 + mathe_nak_test > 80), n=1000000 )
11 [1] 0.645
```

Wie zu erwarten war, prognostiziert das BN hohe Chancen auf überdurchschnittliche Modulergebnisse bei guten Schulnoten. Positiv fällt auf, dass sich mit dem Netz bei der zweiten Frage auch ohne die Information zur hohen Schulnote eine recht gute Chance mit 64,5 Prozent prognostizieren lässt. Dies bedeutet, dass die übrigen Parameter ausreichen, um Studienerfolg zu prognostizieren. Dies spricht für die Qualität von den Parametern dem Netz.

Repräsentantenklasse: Hohe Schulnoten, niedrige Modulnoten (4)

```
1 cpquery(fittedbn, event = (mathe1_modul < 0 ), evidence
2 + = (mathe_abi > 10 & viq_t > 1 & viq_n > 1 &
3 + iqt_logik < 70 & iqt_technik < 70 & mathe_nak_test < 60),
4   n=1000000)
5 [1] 0.5054852
6
7 cpquery(fittedbn, event = (mathe1_modul < 0 ), evidence =
8 + (viq_t > 1 & viq_n > 1 & iqt_logik < 70 &
9 + iqt_technik < 70 & mathe_nak_test <
10 60), n=1000000)
11 [1] 0.3851211
```

In diesem zweiten Szenario erzielte ein Studierender trotz hoher Schulnoten nur mäßige Modulergebnisse. Es ist aufschlussreich, dass ein Studieninteressierter mit überdurchschnittlichen Schulnoten gerade eine Chance von 50,5 Prozent auf überdurchschnittliche Modulergebnisse hat (dieses Szenario skizziert die gestellte Frage). Dies hieße, dass trotz der Schulnote die übrigen Parameter derart mäßig (gemäß der Datenbasis) ausfallen, dass das Netz dem Studieninteressierten dieselben Chancen wie bei einem Münzwurf ausrechnet. Das Netz ließe sich

also nicht von guten Schulergebnissen beirren, anders als die bivariate Statistik auf Basis einer Korrelation. Die zweite Abfrage erfolgt ohne die Information zu den Schulergebnissen. Nur auf Basis der übrigen Parameter rechnet das Netz nun eine Chance auf überdurchschnittliche Modulergebnisse von nur noch 38,5 Prozent aus – die Güte der Aussage hat sich somit ohne die widersprüchlichen Schulergebnisse verbessert.

Repräsentantenklasse: Niedrige Schulnoten, hohe Modulnoten (8)

```
1 cpquery(fittedbn, event = (mathe1_modul < 0 ), evidence =
2 + (mathe_abi < 10 & viq_t > 1 & viq_n > 0 & iqt_logik > 70 &
3 + iqt_technik > 50 & mathe_nak_test > 80), n=1000000)
4 [1] 0.3912843
5
6 cpquery(fittedbn, event = (mathe1_modul < 0 ), evidence =
7 + (viq_t > 1 & viq_n > 0 & iqt_logik > 70 & iqt_technik > 50
8 &
9 mathe_nak_test >80), n=1000000)
[1] 0.5629116
```

Das Netz rechnet dem Studienanwärter eine mit 39,1 Prozent niedrige Erfolgchance aus, wenn dem Netz die Information mitgeteilt wird, dass die Schulnoten des Studieninteressierten niedrig ausfielen. Da bei der ersten Frage ein Studienerfolg nicht attestiert wird, irrt sich das Netz: Der Studieninteressierte erzielte hohe Modulergebnisse.

Die zweite Fragestellung ist hier betrachtenwert: Bei dieser wurden die mäßigen Schulergebnisse in der Frage weggelassen und sich einzig auf die übrigen Parameter konzentriert. Das Netz rechnet dem Anwärter bei der zweiten Frage eine 56,3 prozentige Erfolgchance auf eine überdurchschnittliche Mathe1-Note aus, was den Tatsachen dieses Testdatensatzes entspricht. Dies ist zwar aufgrund der Nähe zur 50-Prozent-Marke so akkurat wie ein Münzwurf, dennoch ist die Aussage weiterhin deutlicher als die Korrelation der bivariaten Statistik. Sie liegt über 50 Prozent und ist damit auch in Tendenzen korrekt. Mit diesem Resultat lässt sich vermuten, dass die Schulnoten nicht die Stärken des Anwärters repräsentieren, was viele Experten in den Interviews ebenfalls deutlich vermutet haben. Wie bereits erarbeitet, sollen die intellektuellen Parameter und die des Ego-Involvements losgelöst sein von subjektiven Bewertungen.

Repräsentantenklasse: Niedrige Schulnoten, niedrige Modulnoten (11)

```
1 cpquery(fittedbn, event = (mathe1_modul < 0 ), evidence =
2 + (mathe_abi < 10 & viq_t < 1 & viq_n > 1 &
3 + iqt_logik < 60 & iqt_technik > 80 ), n=10000)
4 [1] 0.305304
5
6 cpquery(fittedbn, event = (mathe1_modul < 0 ), evidence =
7 + ( viq_t < 1 & viq_n > 1 &
8 + iqt_logik < 60 & iqt_technik > 80 ), n=10000)
9 [1] 0.4004499
```

Bei der umgekehrten Notenlage schneidet das BN bei der ersten Befragung schlechter ab, da es sich augenscheinlich stark von schlechten Schulergebnissen beeinflussen lässt.

Der NAK-Mathematik-Test wies bei diesem Studierenden einen Wert von 100 Prozent auf. Dieser hohe Wert passt nicht zu den übrigen 8 Datensätzen aus Abschnitt A.3, weshalb dieser Wert weggelassen wurde – ansonsten würden die Ergebnisse weit schlechter ausfallen. Eine solche Entscheidung sollte stets der Befrager des Expertensystems evaluieren. Die Chance auf ein gutes Abschneiden fällt mit 30,5 Prozent mit Schulergebnissen und 40 Prozent ohne diese mäßig aus. Auch hier liegt das Netz somit richtig.

Auswertung der Ergebnisse und Methodenkritik

```
1 > cpquery(fittedbn, event = (mathe1_modul < 0 ), evidence =
2 + (viq_t > 1 & viq_n > 0 & iqt_logik > 70 & iqt_technik > 50
3 & mathe_nak_test >80), n=1000000)
4 *generated a grand total of 1e+06 samples.
5   > event matches 68131 samples out of 121316 (p =
6     0.5615995).
7 [1] 0.5615995
```

Das obige Code-Listing verdeutlicht die Arbeitsweise einer Anfrage. Das Netz generiert mit dem Parameter $n=1.000.000$ eine Million Samples auf Basis der Daten, für die es dann bestimmt, ob diese sich in der Anfrage der Evidenzen widerspiegeln. Es wird daraufhin geprüft, wie viele dieser Evidenzen zum Event passen (siehe obiges Code-Listing). Dies ist der p-Wert und somit die Wahrscheinlichkeit für Studienerfolg bezogen auf das angegebene Modulergebnis. Diese Wahrscheinlichkeit bezieht sich somit rein auf die Zugehörigkeit zu den vorhandenen Daten. Dies entspricht der Definition von Predictive Analytics.

5.3.3. Gegenüberstellung mit der bivariaten Statistik

Selbst mit den z-standardisierten Modulergebnissen ändern sich die Aussagen aus der Voruntersuchung der bivariaten Statistik in Abschnitt 4.2 nicht. Die stärkste Korrelation wird zwischen den Schulmathematik-Noten und den Mathe1-Modulnoten mit $r = 0,425$ erreicht. Dies entspricht einer Varianzaufklärung von $(0,425)^2 = 0,18$. Das heißt, dass lediglich 18 Prozent der Varianz des ersten Mathemoduls durch die schulischen Mathenoten erklärt werden können. Mit anderen Worten: Nur bei jedem fünften Studieninteressierten lässt sich überhaupt eine Aussage dazu machen. Dies ist ein sehr dürftiges Ergebnis, erbringt doch ein Münzwurf zumindest eine Trefferquote von 50 Prozent.

Demgegenüber stehen die gezielten Fragen des Bayesschen Netzes, das mit stellenweise 70 Prozent Wahrscheinlichkeit die richtigen Ergebnisse prognostizieren konnte, selbst wenn die Korrelation aus Schulnoten zu Modulnoten verlassen und sich auf die Parameter des Ego-Involvement konzentriert wurde. Allerdings ist ein BN als Datenstruktur schwer zu durchdringen und erzeugt mitunter verwirrende oder inkonsistente Aussagen. Es ist somit weit sprunghafter als die bivariate Statistik, deren Aussagen sich nicht verändern.

5.4. Eignungsevaluation

Nach der empirischen Untersuchung ist deutlich geworden, dass ein Netz aufschlussreiche Ergebnisse liefern kann. Es sind zudem im Laufe dieser Arbeit einige deutliche Schwächen eines solchen Ansatzes deutlich geworden. Dieser Abschnitt fasst die Vor- und Nachteile der Bayesschen Netze für den Anwendungsfall dieser Arbeit zusammen.

5.4.1. Schwächen des Bayesschen Netzes

Ein gut funktionierendes Bayessches Netz erfordert vor allem quantitativ und qualitativ hochwertige Daten. Für diese Arbeit werden 1.100 Datensätze genutzt, was normalerweise den quantitativen Ansprüchen gemäß Zuk, Margel und Domany (2012) nicht gereicht. Daneben sind es Daten, die sehr unterschiedlichen Menschen in einem relativ kurzen Verfahren – dem Nordakademie-Auswahltest – unter nicht-klinischen Bedingungen abgewonnen werden. Dies sorgt verständlicherweise für schwache und undeutliche Zusammenhänge. All dies erschwert den seriösen Einsatz eines Bayesschen Netzes.

Bayessche Netze sind abstrakt und schwer greifbar. Dies stellt eine Eintrittsbarriere für den Einsatz von BNs für Analysen dar. Eine weitere Schwäche zeigt sich bei der Untersuchung dieser Arbeit: Befragungen eines solchen Netzes müssen „blind“, also ohne das Wissen um die tatsächlichen Resultate erfolgen, da es Modulergebnisse der Studieninteressierten in einem realen Einsatz vor dem Studienantritt noch nicht geben kann. In dieser Arbeit wurden Auffälligkeiten in den Daten berücksichtigt, um gezielte Anfragen zu stellen. Anders sähe es aus, wenn tatsächlich ein ganzer Jahrgang anhand eines solchen Netzes evaluiert werden soll, ohne Gewissheit über den Ausgang zu haben.

5.4.2. Stärken des Bayesschen Netzes

Durch Benutzung der Korrelationstabellen ist vor allem eine Stärke Bayesscher Netze deutlich geworden: Sie sind in der Lage, Zusammenhänge besonders kompakt darzustellen, und können dabei analytische Methoden anbieten. Ferner sind Bayessche Netze nicht starr und unveränderlich. Struktur und Wahrscheinlichkeitstabellen liegen getrennt vor. Mit sich verändernder Datenbasis – , wenn z.B. neue Daten hinzu kommen – kann sich ein BN dynamisch entwickeln und anpassen. Eine Schwäche der bivariaten Statistik ist – zumindest bei einfachen Mitteln – die Unklarheit darüber, was durch das Bestimmtheitsmaß oder die Korrelation erklärt wird und was nicht. Es lassen sich nur Aussagen über die Zusammenhänge von Datenmengen treffen. Ob dies für einen Repräsentanten einer Menge zwangsläufig gilt, sagt die Korrelation nicht aus. Die für diese Arbeit bedeutendste Stärke Bayesscher Netze ist die Berücksichtigung von mehr als einer Variable. Die Schulnoten sagen z.B. nichts darüber aus, woher eine solche Note stammt, ob der Schüler und die Lehrkraft ein positives oder negatives Verhältnis hatten oder ob äußere Einflüsse die Schulleistung begünstigt oder erschwert haben. Da ein Bayessches Netz neben Schulnoten auch MIX, ViQ oder IQt berücksichtigt, ist eine Aussage wesentlich neutraler und weniger beeinflusst von solchen Unterschieden in der Erhebung.

6. Kritische Eignungsdiskussion und Handlungsempfehlung

Nach der Erstellung und Erprobung des Expertensystems werden in diesem Abschnitt die bisherigen Ergebnisse resümiert. Es wird ein abschließendes Fazit gezogen.

6.1. Zusammenfassung der bisherigen Ergebnisse

Eingangs wurde in Abschnitt 1.2 aufgezeigt, dass sich die Studieneignungsdiagnostik aktuell in zwei Lager teilt: Eines, das die schulischen Noten für den einzig richtigen Indikator hält und eines, das auch Konzepte des s.g. *Ego-Involvement* berücksichtigt. Die Studienerfolge dieser beiden Lager widersprechen sich oftmals und kommen zu gegensätzlichen Empfehlungen. Die Parametererhebung und Erarbeitung eines Expertensystems in dieser Untersuchung wurde zuvor nicht verfolgt und stellt die Forschungslücke dar.

Die Öffnung für eigene Auswahlverfahren jeder Hochschule im Hochschulgesetz wurde in Abschnitt 2.1 skizziert und verdeutlicht, dass die Frage nach den besten Eignungsparametern auch in Zukunft von Relevanz ist. Die FH Nordakademie führt seit mehreren Jahren einen Auswahltest unter den Studieninteressierten durch, dessen Erfassung und Ergebnisse in Abschnitt 2.5 beschrieben sind. Vor allem die Parameter *ViQ* und *MIX* können dabei direkt dem Ego-Involvement zugeordnet werden. Weitere Parameter sind ein Englisch- und Mathematik-Test, sowie ein technischer IQ (IQ_t). All diese Parameter eröffnen die Chance, sie zusätzlich zu schulischen Noten für die Eignungsdiagnostik zu nutzen. In Abschnitt 2.2 wurde erarbeitet, dass diese Studieneignungsdiagnostik andere Methoden und Ziele kennt als die Personaleignungsdiagnostik.

Die Grundlagen aus Kapitel 3 wurden dazu genutzt, in Kapitel 4 ein modellhaftes Bayessches Netz (BN) zu erstellen. Dafür wurden Korrelationstabellen genutzt, die Aufschluss darüber geben, welche Parameter bedingt abhängig sein könnten. Dies wurde mit Experten in Interviews diskutiert. Darauf basierend wurde ein BN erzeugt.

Dieses BN wurde in Kapitel 5 durch die Daten iterativ verbessert. Anschließend wurde ein hybrides BN mittels Struktur-Lernalgorithmus MMHC und Expertenparametern gebaut. Testdaten wurden letztlich genutzt, um die Stärken und Schwächen des Systems ausfindig zu machen. Es zeigte sich, dass das Netz stellenweise bessere Prognosen erlaubt als die bivariate Statistik. Allerdings gab es auch Abweichungen.

6.2. Beantwortung der Hypothesen

Mit diesen durch die Arbeit gewonnenen Erkenntnissen und Eindrücken ist es möglich, die Hypothesen aus Abschnitt 1.3 zu beantworten.

6.2.1. Erste Hypothese (h1)

Die erste Hypothese aus Abschnitt 1.3 besagt, dass das Ego-Involvement zusätzliches Analysepotenzial bietet. Dies ist eher abzulehnen. Zum einen stellen schulische Noten tatsächlich die größte Güte als Eignungsindikatoren dar – auch wenn dies nicht sehr deutlich ausfällt. Zum anderen sind es vor allem der IQt und Nordakademie-Mathematiktest, die auf eine Eignung hinweisen können. Der ViQ spielt eine nur untergeordnete Rolle – lediglich die Werte ViQ-t und ViQ-n wirken sich nennenswert auf die Modulergebnisse aus. Die MIX-Werte spiegeln sich kaum in den Zusammenhängen wider, wie das Schaubild Abbildung 14 zur Verbindungsstärke zeigt. Daher muss zu dem Schluss gekommen werden: Zumindest der vorliegenden Datenbasis nach zu urteilen, spielen die Parameter zum Ego-Involvement, d.h. MIX und ViQ, kaum eine Rolle für die Eignungsdiagnostik. Dies könnte sich mit einer größeren Datenmenge relativieren. Das wäre eine Aufgabe für eine fortführende Untersuchung.

6.2.2. Zweite Hypothese (h2)

Die zweite Hypothese besagte, dass ein dynamisches Expertensystem die Anforderungen besser erfülle als eine statische Betrachtung. Diese Hypothese kann bestätigt werden. Die bivariate Statistik mit der oft genutzten Maßzahl der Korrelation, dem Korrelationskoeffizienten, ermöglicht Aussagen zur Gesamtmenge aller vorhandenen Daten. Es lässt sich sagen, dass der größte Zusammenhang unter den Notenwerten aus Schule und Hochschule besteht. Diese Aussage läuft besonders dann Gefahr falsch zu sein, wenn Individuen aus dieser Datenmenge

betrachtet werden. Auf einzelne Individuen ist solch eine Aussage über die Gesamtmenge nur schwer anwendbar. Genau dies ist jedoch die Anforderung an Studieneignungsdiagnostik. Es werden Individuen betrachtet. Hier weist die Statistik somit signifikante Schwächen auf. Ein Expertensystem auf Basis eines Bayesschen Netzes ermöglicht jedoch, wie in Abschnitt 5.3 gezeigt, die Betrachtung von Individuen. Semi-dynamisch verändert das BN die Aussage anhand der Evidenzen, die dem Netz bei einer Frage mitgeteilt werden. Semi-Dynamik bedeutet hier, dass sich nicht das gesamte System ändert. Die CPT wurden bereits zuvor durch die Fitness-Funktion ermittelt und verändern sich bei einer Inferenz-Abfrage nicht. Diese Semi-Dynamik ist besser geeignet für die Studieneignungsdiagnostik, als es die (*einfache*) bivariate Statistik wäre.

Ein weiterer Umstand macht ein dynamisches System wie das BN umso mächtiger: Struktur und bedingt abhängige Wahrscheinlichkeiten werden in dem Datentyp *Bayessches Netz* getrennt hinterlegt. Pro Abfrage werden Samples auf Basis der Wahrscheinlichkeiten erzeugt und dann gefragt, zu welchem Anteil dieser Samples die Abfrage passt. Man stelle sich nun vor, das vorgestellte BN wird in der Struktur beibehalten und die Datenbasis um zehn neue Studierende erweitert. Die Fitness-Funktion ist sehr schnell durchgeführt, wonach bereits mit der erweiterten Datenbasis gefragt werden kann. Diese zehn Neuankömmlinge können mit sehr außergewöhnlichen Parameter-Vernetzungen die Antworten des Expertensystems massiv beeinflussen. So bleibt das BN stets auf dem neuesten, aktuellsten Stand – es passt sich dynamisch einer veränderlichen Datenbasis an. Diese Dynamik wäre bei der bivariaten Statistik nicht anzutreffen. Eine Korrelationsaussage bezieht sich immer auf die Masse aller Daten. Ein Datensatz mehr oder weniger macht dabei kaum einen Unterschied. Dies ist eine Schwäche von Noten als „Pauschal-Indikator“: Individualergebnisse gehen in der Masse verloren und werden missachtet.

Sehr deutlich werden diese gerade aufgeführten Aussagen an den Testergebnissen aus dieser Arbeit. Die bivariate Statistik weist eine maximale Korrelation von $r = 0,46$ auf, was einer Varianzaufklärung von $R^s = 0,46^2 = 0,2116$, also circa 21 Prozent entspricht. Nur 21 Prozent der Varianz können überhaupt durch die Statistik erklärt werden. Ein Münzwurf weist eine Aufklärung von 50 Prozent auf. Somit ist ein Münzwurf besser geeignet. Das Bayessche Netz führte nur bei einer einzigen Abfrage zu einer falschen Aussage (hohe Abitur-Ergebnisse mit späteren mäßigen Modulergebnissen), wobei das Weglassen von Abitur-Noten die Aussagen bei vielen Abfragen zuverlässiger gemacht haben. Wie schon eingangs in Kapitel 1 dargestellt, stehen Noten schon seit Jahren und heutzutage umso mehr in der Kritik. Es ist von „Noteninflation“ die Rede. Die Güte von Noten als Indikatoren wird zunehmend hinterfragt. Werden die

Schulnoten bei einer BN-Frage weggelassen, verbessert sich die Aussage des Netzes und sie wird akkurater. Somit kann vermutet werden, dass Noten nicht das wirkliche Potenzial eines Anwärters widerspiegeln.

Somit lässt sich die Frage nach der Güte von einem dynamischen System deutlich positiv beantworten, besonders wenn beachtet wird, dass sich die so wichtige Datenbasis zu Studierenden Jahr für Jahr an einer Hochschule wie der Nordakademie vergrößern wird. Mit einer wachsenden Datenbasis wächst auch die Güte eines dynamischen Systems.

6.3. Ableitung einer allgemeingültigen Handlungsempfehlung für ähnliche Problemstellungen

Die wohl wichtigste Erkenntnis, die aus dieser Arbeit gewonnen werden kann, ist – neben der eigentlichen Frage nach Eignung und Güte eines Expertensystems auf Basis eines Bayesschen Netzes – die Frage danach, wie ein solches Expertensystem generell aus vorhandenen Daten erstellt werden kann.

Als erstes sollte eine Zielsetzung formuliert werden. Für ein Bayessches Netz und ein Expertensystem braucht es eine konkrete Problemstellung und vor allem eines: Daten. Diese Daten dürfen nicht nur „auf Verdacht“ in großen Quantitäten angehäuft werden. Die Qualität der Daten muss hoch sein, damit ein BN sinnvolle Ergebnisse ermöglicht. Dafür sollten Daten gezielt erfasst werden. Anschließend sollten Daten statistisch untersucht werden. Zeigt die univariate Statistik von sehr gestreuten, nicht-linearen Datenbeständen, so wird auch ein Bayessches Netz qualitativ schwach ausfallen. Ferner kann ein Bayessches Netz Zusammenhänge aufzeigen, die mit der bloßen bivariaten Statistik nur schwer zu sehen sind. Doch existieren nach der bivariaten Statistik keinerlei Zusammenhänge, wird ein solches BN sie vermutlich ebenfalls nicht aufzeigen können. Solch ein Netz kann nichts zeigen, das nicht bereits existiert.

Im Anschluss daran sollten die Daten aufbereitet werden. Im Idealfall sollten sie in Klassen eingeteilt, d.h. diskretisiert werden. Ferner empfiehlt es sich, sie auf vergleichbare Maße zu bringen, z.B. indem starke Ausreißer entfernt werden. Sofern möglich, empfiehlt es sich, besonders viele Daten anzusammeln oder mehr Datensätze vergleichbar zu machen. Nach dem Struktur-Lernen durch einen Algorithmus sollten stets Experten nach Güte und Richtung von

Verbindungen befragt werden. Die Korrelation zu nutzen, ist eine Möglichkeit zur Modellierung eines weiteren zu diskutierenden BN-Modells. Diese Erkenntnisse können wiederum genutzt werden, um anhand von Scoring-Algorithmen die Qualität des Netzes zu erhöhen. Testdaten müssen aus der Datenbasis entnommen werden. Anschließend werden die bedingten Wahrscheinlichkeiten z.B. durch den EM-Algorithmus erlernt. Abfragen an das Netz sollten kritisch geprüft werden, weil sie falsch sein können. Nur auf Basis eines solchen Expertensystems sollten eignungsdiagnostische Fragen nicht entschieden werden. Der Mensch ist die letzte Instanz einer solchen Entscheidung.

Zu guter Letzt sollte beachtet werden, dass sich ein BN mit veränderlicher Datenbasis ebenfalls in der Struktur verändern sollte, um immer bestmöglich zu den Daten zu passen. Dies bedeutet auch, dass ein solches System gepflegt und fortwährend analysiert werden muss. Ansonsten verliert es seine Zulässigkeit.

6.4. Fazit und Ausblick

Die Untersuchung hat ergeben, dass ein Expertensystem auf Basis eines Bayesischen Netzes gegenüber der bivariaten Statistik deutliche Stärken aufweist. So führte die Betrachtung von weiteren Parametern des Auswahltests neben den Noten zu teils deutlich akkurateren Aussagen, als es die Statistik zuließ. Mehr noch: Wurden Schulnoten bei Anfragen an das Expertensystem weggelassen, ergaben die Prognosen mehrheitlich noch präzisere Ergebnisse. Dies spricht gegen eine einseitige Betrachtung von Schulnoten und für einen Parameter-Mix, wie es der Auswahltest der Nordakademie mit dem BN ermöglicht. Ferner wurde aufgezeigt, wie ein solches Expertensystem generell für gleichartige Problemstellungen abgeleitet und so für unterschiedliche Anwendungsdomänen erstellt werden kann.

Für den in dieser Untersuchung betrachteten Anwendungsfall ist zu beachten, dass die Art des erarbeiteten Expertensystems bislang nicht für einen realen Einsatz zur Eignungsdiagnostik von Studieninteressierten der Nordakademie tauglich wäre. Dafür ist das erstellte System zu experimentell, die Datenbasis zu klein und die Struktur des Bayesischen Netzes mit dessen Stärken und Schwächen in dieser Arbeit zu schwach beleuchtet. Hier eröffnet sich ein guter Ansatzpunkt für weiterführende Studien. Hilfreiche Denkanstöße als Expertensystem für die Eignungsdiagnostik kann das System bereits in dieser Form geben. Die Grundsteine für eine lohnende tiefgreifende Betrachtung des Analyse-Potenzials mittels eines Expertensystems auf Basis eines Bayesischen Netzes sind mit dieser Untersuchung gelegt.

Literatur

Association, American Psychological (2013). *Journal of Experimental Psychology Volume 3*. Bd. 3. 145 Bde. Journal of Experimental Psychology. Harppress Publishing. 514 S. ISBN: 978-1-313-26987-2.

Behringer, Stefan (2016). *Modulhandbuch B.Sc. Angewandte Informatik*.

Bosch, Karl (1999). *Mathematik-Lexikon: Nachschlagewerk und Formelsammlung für Anwender*. München: Oldenbourg Wissenschaftsverlag. 844 S. ISBN: 978-3-486-24243-0.

Bourier, Gunther (2014). *Beschreibende Statistik: Praxisorientierte Einführung - Mit Aufgaben und Lösungen*. 12. Aufl. Wiesbaden: Springer Gabler. 292 S. ISBN: 978-3-658-05915-6.

Collin, Catherine u. a. (2012). *The Psychology Book*. New York: DK. 352 S. ISBN: 978-0-7566-8970-4.

Elkan, Charles (2013). *Predictive analytics and data mining*. Jacobs School of Engineering. URL: http://cseweb.ucsd.edu/~jmcauley/cse255/files/elkan_dm.pdf (besucht am 11.07.2016).

Ertel, Wolfgang (2016). *Grundkurs Künstliche Intelligenz: Eine praxisorientierte Einführung*. 4. Aufl. Springer Vieweg. 404 S. ISBN: 978-3-658-13548-5.

Feigenbaum, Edward A und Bruce G Buchanan (1971). *A heuristic programming study of theory formation in science*. Computer Science Department.

Gibney, Elizabeth (2016). "Google AI algorithm masters ancient game of Go". In: *Nature* 529.7587, S. 445–446. ISSN: 0028-0836, 1476-4687. DOI: 10.1038/529445a. URL: <http://www.nature.com/doi/10.1038/529445a> (besucht am 02.08.2016).

- Hart-Davis, Adam u. a. (2015). *Das Wissenschafts-Buch*. München: Dorling Kindersley. 352 S. ISBN: 978-3-8310-2826-9.
- Hartmanis, J. und R. E. Stearns (1965). “On the Computational Complexity of Algorithms”. In: *Transactions of the American Mathematical Society* 117, S. 285–306. ISSN: 0002-9947. DOI: 10.2307/1994208. URL: <http://www.jstor.org/stable/1994208> (besucht am 07. 11. 2016).
- Hebb, Donald Olding (1949). *The Organization of Behavior: A Neuropsychological Theory*. Wiley.
- Hell, Benedikt, Sabrina Trapmann und Heinz Schuler (2007). “Eine Metaanalyse der Validität von fachspezifischen Studierfähigkeitstests im deutschsprachigen Raum”. In: Jahrgang 21 (Heft 3), S. 251–270.
- (2008). “Synopsis der Hohenheimer Metaanalysen zur Prognostizierbarkeit des Studienerfolgs und Implikationen für die Auswahl- und Beratungspraxis”. In: *Studierendenauswahl und Studienentscheidung*. 1., Aufl. Hogrefe Verlag, S. 43 –56.
- Herrmann, Theo (2002). *Hochschulentwicklung - Aufgaben und Chancen*. Heidelberg: Asanger, R. ISBN: 978-3-89334-327-0.
- Heublein, Ulrich u. a. (2014). *DZHW - Forum Hochschule 4 | 2014 - fh-201404.pdf*. 4. Deutsches Zentrum für Hochschul- und Wissenschaftsforschung, S. 26. URL: http://www.dzhw.eu/pdf/pub_fh/fh-201404.pdf (besucht am 10. 07. 2016).
- Johannßen, Dirk (2016). *Exposé zur Master Thesis mit dem Arbeitstitel Eignungsdiagnostik durch Predictive Analytics mit Fokussierung auf maschinellem Lernen am Beispiel von Studienerfolgspotenzialen zukünftiger Softwareentwickler*.
- Jones, John (2016). *Venn diagram*. In: *Wikipedia*. URL: https://en.wikipedia.org/w/index.php?title=Venn_diagram&oldid=750977410 (besucht am 22. 12. 2016).

- Keller, Daniela (2015). *Signifikanztest und Fehler 1. und 2. Art*. Statistik und Beratung - Daniela Keller. URL: <http://www.statistik-und-beratung.de/2015/02/fehler-beim-statistischen-testen/> (besucht am 15. 12. 2016).
- Kolanoski, Hermann (2008). *Statistische Methoden der Datenanalyse - Skript zur Vorlesung im Sommersemester 2008*. URL: https://www-zeuthen.desy.de/~kolanosk/smd_ss08/skripte/skript.pdf (besucht am 25. 11. 2016).
- Lazer, David u. a. (2014). “The Parable of Google Flu: Traps in Big Data Analysis”. In: *Science* 343.6172, S. 1203–1205. ISSN: 0036-8075, 1095-9203. URL: <http://science.sciencemag.org/content/343/6172> (besucht am 26. 07. 2016).
- McCarthy, John (1960). *Programs with Common Sense*. Cambridge, MA, USA: Massachusetts Institute of Technology.
- McCulloch, Warren S. und Walter Pitts (1943). “A logical calculus of the ideas immanent in nervous activity”. In: *Bulletin of Mathematical Biophysics* 5.4, S. 115–133. ISSN: 0007-4985, 1522-9602. DOI: 10.1007/BF02478259. URL: <http://link.springer.com/article/10.1007/BF02478259> (besucht am 11. 07. 2016).
- Meuer, Hans (2016). *June 2016 | TOP500 Supercomputer Sites*. URL: <https://www.top500.org/lists/2016/06/> (besucht am 28. 07. 2016).
- Miikkulainen, Alex Lubberts {and} Risto (2001). “Co-Evolving A Go-Playing Neural Network”. In: URL: <http://nn.cs.utexas.edu/?lubberts:geccows01> (besucht am 28. 07. 2016).
- Münsterberg, H. (1914). *Grundzüge Der Psychotechnik*. 785 S. ISBN: 978-1-147-88819-5.
- Ng, Andrew (2017). *The EM algorithm*. URL: <http://cs229.stanford.edu/notes/cs229-notes8.pdf> (besucht am 07. 01. 2017).
- Owsnicki-Klewe, Bernd (2002). *Algorithmen und Datenstrukturen. Inf & Ing, Bd. 5*. 5. Aufl. Augsburg: Wißner-Verlag. 224 S. ISBN: 978-3-89639-172-8.

- Pavlov, Ivan Petrovich (1928). *Lectures on conditioned reflexes*. International publishers. 430 S.
- Petersson, Mikael (2010). *The Maximum Minimum Parents and Children Algorithm*. URL: <http://liu.diva-portal.org/smash/get/diva2:332341/FULLTEXT01.pdf> (besucht am 07.01.2017).
- Plate, Georg (2016a). *Bewerbungen - NORDAKADEMIE - Hochschule der Wirtschaft*. URL: <https://www.nordakademie.de/bewerber/bewerbungen/> (besucht am 25.11.2016).
- (2016b). *Duale Bachelorstudiengänge - NORDAKADEMIE - Hochschule der Wirtschaft*. URL: <https://www.nordakademie.de/bewerber/duale-bachelorstudiengaenge/> (besucht am 26.11.2016).
- (2016c). *Modulhandbuch B.Sc. BWL*.
- (2016d). *Modulhandbuch B.Sc. Wirtschaftsinformatik*.
- (2016e). *Modulhandbuch B.Sc. Wirtschaftsingenieurwesen*.
- Plaue, Matthias und Mike Scherfner (2009). *Mathematik für das Bachelorstudium I: Grundlagen, lineare Algebra und Analysis*. 2009. Aufl. Spektrum Akademischer Verlag. 306 S. ISBN: 978-3-8274-2067-1.
- Price, Mr (2013). *An Essay towards Solving a Problem in the Doctrine of Chances By the Late Rev. Mr. Bayes F. R. S. Communicated by Mr. Price in a Letter to John Canton A. M. F. R. S. Vol: 53 1763*. Isha books. ISBN: 978-93-331-5961-6.
- Rentschler, Michael und Hans P. Voss (2008). *Studieneignung und Studierendenauswahl: Untersuchungen und Erfahrungsberichte*. 1. Aufl. Aachen: Shaker. ISBN: 978-3-8322-7419-1.
- Rumelhart, David E und James L McClelland (1987). *Parallel distributed processing*. Bd. 2. MIT press Cambridge, MA.

- Russell, Stuart und Peter Norvig (2012). *Künstliche Intelligenz*. 3. Aufl. München u.a.: Pearson Studium. 1312 S. ISBN: 978-3-86894-098-5.
- Sarges, Werner und David Scheffer (2008). *Innovative Ansätze für die Eignungsdiagnostik*. 1. Aufl. Göttingen, Niedersachs: Hogrefe Verlag. ISBN: 978-3-8017-2182-4.
- Scheffer, David (2016). *Der Mensch ist ein duales Wesen*. URL: https://www.nordakademie.de/aktuelles/aktuelldetail/der-mensch-ist-ein-duales-wesen/?no_cache=1&cHash=c04439717d3e4c349ec4a37e41856401 (besucht am 19. 12. 2016).
- Scheffer, David und Dieter Loerwald (2008). “Messung von Persönlichkeitseigenschaften mit dem Visual Questionnaire (ViQ)”. In: *Innovative Ansätze für die Eignungsdiagnostik*. 1. Aufl. Göttingen, Niedersachs: Hogrefe Verlag, S. 51–63. ISBN: 978-3-8017-2182-4.
- Scheffer, David u. a. (2016). *An implicit Approach in Measuring Personality Traits by the Visual Questionnaire (ViQ®): Psychometric Properties, Validation and Scope of Application*. URL: <http://viq-academy.de/wp-content/uploads/2016/06/ViQ-White-Paper.pdf> (besucht am 08. 01. 2017).
- Schira, Josef (2012). *Statistische Methoden der VWL und BWL: Theorie und Praxis*. 4. Aufl. Pearson Studium. 624 S. ISBN: 978-3-86894-117-3.
- Schleithoff, Fabian (2015). “Noteninflation im deutschen Schulsystem – Macht das Abitur hochschulreif”. In: *ORDO – Jahrbuch für die Ordnung von Wirtschaft und Gesellschaft*. Bd. 66. De Gruyter Oldenbourg, S. 3–26. ISBN: 978-3-8282-0621-2.
- Schmidt, Birte (2010). “Erfolgreich ist der, der ankommt, weiß der Marathonläufer”. In: URL: <http://www.abendblatt.de/wirtschaft/karriere/article107848107/Erfolgreich-ist-der-der-ankommt-weiss-der-Marathonlaeufer.html> (besucht am 30. 12. 2016).
- Scholz, Christian (2016). “Wirtschaftspsychologie aktuell - Zeitschrift für Personal und Management: Smart durch Big Data? Plädoyer für eine kritische Betrachtung”. In: *Wirtschaftspsychologie aktuell* New Work.2, S. 68. ISSN: 1611-9207. URL: <http://www.wirtschaftspsychologie-aktuell.de/> (besucht am 18.07.2016).

- Schraudolph, Nicol N., Peter Dayan und Terrence J. Sejnowski (1994). “Temporal Difference Learning of Position Evaluation in the Game of Go”. In: *Advances in Neural Information Processing Systems 6*. Bd. 6. San Diego, CA 92186-5800: Morgan Kaufmann, S. 817–824.
- Schuler, Heinz und Benedikt Hell (2008). “Studierendenauswahl und Studienentscheidung aus eignungsdiagnostischer Sicht”. In: *Studierendenauswahl und Studienentscheidung*. 1., Aufl. Hogrefe Verlag, S. 11 –17.
- Schwarz, Jörg und Heidi Bruderer Enzler (2016). *Methodenberatung der Universität Zürich. Rangkorrelation nach Spearman*. URL: <http://www.methodenberatung.uzh.ch/de/datenanalyse/zusammenhaenge/rangkorrelation.html> (besucht am 10. 12. 2016).
- Scutari, Marco und Jean-Baptiste Denis (2014). *Bayesian Networks: With Examples in R*. s.l.: Chapman & Hall/Crc Texts in Statistical Science. 241 S. ISBN: 978-1-4822-2558-7.
- Sherif, Muzafer (1966). *The Psychology of Ego-Involvements. Social Attitudes & Identifications*. Wiley, New York: New York: JOHN WILEY, SONS, Inc., London: CHAPMAN und HALL, Limited.
- Shum, Harry (2017). *MSBNx*. URL: <http://research.microsoft.com/en-us/um/redmond/groups/adapt/msbnx/> (besucht am 10.01.2017).
- Silver, David u. a. (2016). “Mastering the game of Go with deep neural networks and tree search”. In: *Nature* 529.7587, S. 484–489. ISSN: 0028-0836. DOI: 10.1038/nature16961. URL: <http://www.nature.com/nature/journal/v529/n7587/full/nature16961.html> (besucht am 28. 07. 2016).
- Staab, Frank (2012). *Logik und Algebra: Eine Praxisbezogene Einführung Für Informatiker Und Wirtschaftsinformatiker*. 2. Aufl. De Gruyter Oldenbourg. 160 S. ISBN: 978-3-486-71697-9.
- Taylor, Frederick Winslow (2011). *The Principles of Scientific Management*. Charleston, South Carolina: CreateSpace Independent Publishing Platform. 114 S. ISBN: 978-1-4609-6998-4.

- Tromp, John (2016). *Number of legal positions in Go played on an $n \times n$ grid*. The online encyclopedia of integer sequences. URL: <https://oeis.org/A094777> (besucht am 26.07.2016).
- Tsamardinos, Ioannis, Laura E. Brown und Constantin F. Aliferis (2006). “The Max-Min Hill-Climbing Bayesian Network Structure Learning Algorithm”. In: *ResearchGate* 65.1, S. 31–78. ISSN: 0885-6125. DOI: 10.1007/s10994-006-6889-7. URL: https://www.researchgate.net/publication/220343713_The_Max-Min_Hill-Climbing_Bayesian_Network_Structure_Learning_Algorithm (besucht am 07.01.2017).
- Ulich, Eberhard (2011). *Arbeitspsychologie*. 7., überarbeitete und aktualisierte. Zürich: Schäffer-Poeschel. 908 S. ISBN: 978-3-7281-3370-0.
- Urbanek, Simon und Martyn Plummer (2017). *R: The R Project for Statistical Computing*. URL: <https://www.r-project.org/> (besucht am 10.01.2017).
- W., David (2017). *Directed acyclic graph*. In: *Wikipedia*. URL: https://de.wikipedia.org/wiki/Datei:Directed_acyclic_graph.svg (besucht am 06.01.2017).
- Weicker, Karsten (2015). *Evolutionäre Algorithmen*. 3. Aufl. Wiesbaden: Springer Vieweg. 344 S. ISBN: 978-3-658-09957-2.
- Yan, Wenying u. a. (2010). “Effects of Time Point Measurement on the Reconstruction of Gene Regulatory Networks”. In: *Molecules* 15.8, S. 5354–5368. DOI: 10.3390/molecules15085354. URL: <http://www.mdpi.com/1420-3049/15/8/5354> (besucht am 07.01.2017).
- Zimmerhofer, Alexander und Günter Trost (2008). “Auswahl- und Feststellungsverfahren in Deutschland - Vergangenheit, Gegenwart und Zukunft”. In: *Studierendenauswahl und Studienentscheidung*. 1., Aufl. Hogrefe Verlag, S. 32–42.
- Zuk, Or, Shiri Margel und Eytan Domany (2012). “On the Number of Samples Needed to Learn the Correct Structure of a Bayesian Network”. In: URL: <https://dslpitt.org/uai/papers/06/p560-zuk.pdf> (besucht am 30.01.2017).

A. Anhang

Nachfolgend befinden sich Informationen, die zum grundlegenden Verständnis der Arbeit und zur Beantwortung der Hypothesen nicht zwingend notwendig sind, aber darüber hinaus wertvolle Zusätze zu den Themen darstellen. Die entsprechenden Verweise und Hinweise zum Anhang befinden sich im Kerntext dieser Arbeit.

A.1. Datenbasis

Indikator	Wert	Indikator	Wert
id	490	englisch_durchschnitt_bsc	0,6
mix_leistung	75	englisch_durchschnitt_abi	10,5
viq_s	1,3	iqt_merkfaehigkeit	99
fachbereich	BWINF	viq_e	0,89
mix_bindung	69	viq_n	-1,26
m/w	w	mathe_durchschnitt	12,75
mix_macht	80	iqt_logik	88
viq_t	2,02	mathe	80
alter	18	gesamt_durchschnitt	11,25
iqt_gesamt	95	iqt_rechnen	96
viq_f	-0,15	Programmierung 1	2,7
deutsch_durchschnitt	10,5	iqt_technik	80
iqt_sprache	78	Diskrete Mathematik 1	3,3
kahnemann_durchschnitt		viq_typ	ESTJ
Diskrete Mathematik 2	2,3	viq_j	1,15

Tabelle 13.: Kompletter Datensatz in Rohform. Die Kahnemann-Werte fehlten.

A.2. Historisches Hintergrundwissen: Entwicklung der KI und Paradigmenwechsel in der Studieneignungsdiagnostik

Nachfolgend wird die historische Entwicklung der KI beschrieben.

A.2.1. Von Streichholzschachteln bis zum Computer Go

Die Grundsteine der Künstlichen Intelligenz, wie sie heute als wissenschaftliche Disziplin verstanden wird, wurden bereits zur Zeit des Zweiten Weltkriegs gelegt. Einige bedeutende mathematische Theoreme wurden bereits vor einigen hundert Jahren aufgestellt und bestimmten dennoch die KI-Forschung der jüngsten Vergangenheit.

A.2.1.1. Ein unveröffentlichtes Manuskript eines Theologen als Grundlage moderner probabilistischer Expertensysteme

Die Künstliche Intelligenz kennt viele wissenschaftliche Felder, in denen sie von Relevanz ist und von denen sie Erkenntnisse nutzt. Das logische Schließen ist für die Philosophie und Theologie von großer Bedeutung. Mit der sprachlichen Formalisierung mathematischer Beweisführung lassen sich geisteswissenschaftliche Aussagen und neues Wissen herleiten. Dies erkannte auch der Theologe Thomas Bayes, als er bereits 1763 sein bedeutendes Werk *An Essay towards solving a Problem in the Doctrine of Chances* verfasste, in dem er zum ersten Mal den nach ihm benannten *Satz von Bayes* formulierte (Price 2013, Nachdruck von 1763. Vgl. S. 23).

Die grundlegende Formel

$$P(A | B) = \frac{P(B | A)P(A)}{P(B)}$$

ermöglicht es, die Wahrscheinlichkeit für eine Ursache zu einem gegebenen Effekt zu bestimmen. Der mathematische Hintergrund wird in Abschnitt 3.4 skizziert. Die Erkenntnisse durch das Theorem sind Grundlage vieler und bedeutender Expertensysteme der Moderne.

A.2.1.2. Väter der KI

Die Autoren McCulloch und Pitts (1943) erdachten auf Basis von Analysen der Neuronen im Gehirn, der formalen Analyse der Aussagenlogik von Russel und Whitehead und den Erkenntnissen von Alan Turing ein Konzept zur Abbildung von Neuronen als Modell. Bei diesem Modell wurde die Signalübertragung durch *an* oder *aus* gesteuert. Damit ließ sich Aussagenlogik abbilden. Ferner vermuteten McCulloch und Pitts, dass ein solches Modell lernfähig wäre.

Den Beweis für die Lernfähigkeit des aufgestellten Modells erbrachte Hebb (1949, vgl. S. 63), als er einen einfachen Algorithmus zur Aktualisierung bereits bestehender Verbindungen vorstellte. Diese Aktualisierungsregel wird heute als *Hebbssche Lernregel* bezeichnet und stellt eines der einflussreichsten Modelle der KI-Forschung dar (Russell und Norvig 2012, vgl. S. 39).

A.2.1.3. MENACE

Lange bevor Computer durch Lernalgorithmen Künstliche Intelligenz erwarben, wurden solche Algorithmen bereits an praktischen Beispielen aufgezeigt. So entwarf der britische Forscher Donald Michie mit Streichholzschachteln und Murmeln eine von ihm *Matchbox Educable Noughts And Crosses Engine (MENACE)* getaufte Konstruktion, welche bereits das generelle Prinzip des maschinellen Lernens aufzeigte (Hart-Davis u. a. 2015, vgl. S. 288 ff.). MENACE war in der Lage, die Spielzüge des Spiels *Tic Tac Toe* zu bestimmen. Bei Tic Tac Toe handelt es sich um das abwechselnde Setzen der Symbole X und O durch zwei Spieler. Jeder Spieler hat das Ziel, eine Reihe des eigenen Symbols auf einer 3X3 Matrix zu erzeugen – entweder horizontal, vertikal oder diagonal.

Michie ließ sich für MENACE von der Konditionierung aus dem Tierreich inspirieren, als er Murmeln unterschiedlicher Farben in Streichholzschachteln legte. Jede Murmel war unterschiedlich und stand für eines der Symbole und eine Position auf dem Feld. Jede Schachtel entsprach einem der 304 möglichen Spielstände im Verlauf von Tic Tac Toe, wobei Rotationen oder Spiegelungen des Spielfelds ignoriert wurden. Anfangs waren alle Murmeln gleichverteilt. Die auf die Spitze gestellten Schachteln besaßen eine untere Öffnung, aus der eine Murmel entnommen wurde. Die Murmel entsprach dem nächsten Zug. Am Ende der Partie wurde dann die Konditionierung des Systems unternommen. Für ein erfolgreiches Spiel wurden mehr der *Sieger-Murmeln* in die entsprechenden Schachteln gelegt. Bei einem Patt wurden die Murmeln

lediglich zurückgelegt. Bei einem Verlust des Spiels wurden die *Verlierer-Murmeln* entfernt. Auf diese Weise wurde die Konstruktion für Siege *belohnt*, sodass die erfolgreichen Züge in einer Spielsituation vermehrt ausgeführt werden sollten, oder *bestraft*. Das Prinzip des Systems wird in Abbildung 15 veranschaulicht.

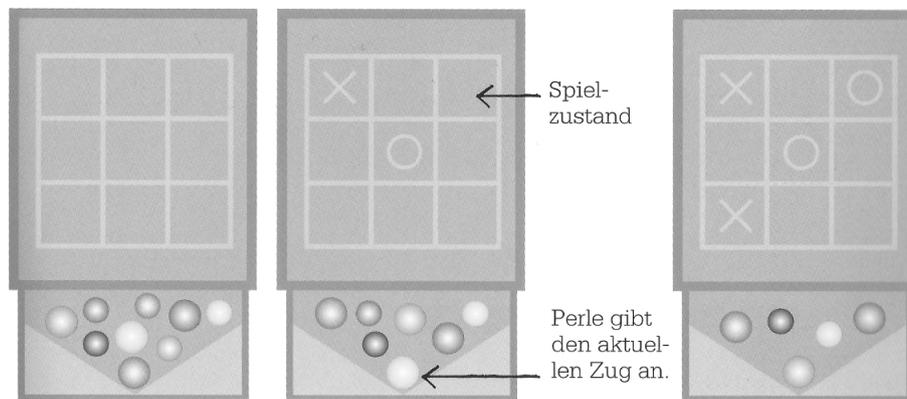


Abbildung 15.: Schematische Darstellung des MENACE-Systems von Michie. In je eine Streichholzschachtel pro Spielstellung werden Murmeln als Neurotransmitter hinzugefügt oder entnommen. (Hart-Davis u. a. 2015, S. 289)

Anfänglich verliert eine solche MENACE-Konstruktion gegen Menschen. Doch nach circa fünfzehn Spielzügen erreicht sie bereits ein hohes strategisches Niveau. Mit dieser Grundsteinlegung eines Lernalgorithmus gilt der Forscher Michie als *Vater der Künstlichen Intelligenz* (Hart-Davis u. a. 2015, vgl. S. 290).

A.2.1.4. Erste Künstliche Intelligenz

Nachdem 1958 am Massachusetts Institute of Technology (MIT) durch John McCarthy die Programmiersprache Lisp entworfen wurde, war es möglich, funktionale Listen nach so genannten Lambda-Ausdrücken zu verarbeiten. Die Zustandslosigkeit der Lisp-Programme schonte die damals sehr knappen Rechenressourcen. Die Sprache entwickelte sich zu einer der wichtigsten Technologien im Forschungsfeld der Künstlichen Intelligenz und wird noch heute für diese Zwecke – zumeist als Dialekt – eingesetzt (Russell und Norvig 2012, vgl. S. 42).

Mithilfe der funktionalen Programmierung entwarf John McCarthy in seinem technologischen Artikel *Programs with Common Sense* das erste System mit Namen *Advice Taker*, welches

die mathematische Logik nutzte (McCarthy 1960, vgl. S. 80ff). Da die zuvor geschriebenen Programme sich auf prozedurale Aufrufe anderer Programme beschränkten, stellte die Nutzung von Logik als Wissensrepräsentation einen entscheidenden Schritt in der Entwicklung der Künstlichen Intelligenz dar. Der *Advice Taker* besaß in seiner Wissensbasis Informationen zur Umgebung und schloss mithilfe von Inferenzen auf neue Zusammenhänge. Damit gilt McCarthy's System als erste KI.

A.2.1.5. Eine jähe Ernüchterung

Nach den anfänglichen Fortschritten in der KI-Forschung stießen die Forscher auf Grenzen der bisherigen Erkenntnisse, die viele Dekaden nicht überwunden werden konnte. So bewiesen Lösungen für einfache Problemstellungen, dass die Künstliche Intelligenz zum Einsatz in solchen Domänen in der Lage war. Dabei wurden häufig Baumstrukturen mit allen möglichen Lösungen traversiert, bis ein Ziel gefunden war. Die Aktionsfolge bis zum Ziel stellte den durchzuführenden Plan dar.

Die anfängliche Euphorie durch Fortschritte auf dem Gebiet der KI sorgte schnell dafür, dass Forscher versuchten, ein Problem zu lösen, dabei aber häufig bereits im Ansatz unzureichende Strategien verfolgten. So war die Annahme, die sprachliche Übersetzung von russischen zu englischen Texten bestünde lediglich aus „einfacher syntaktischer Übertragung“ der Grammatiken (Russell und Norvig 2012, S. 44) und elektronischer Auswahl von Übersetzungen aus einem Wörterbuch, eine Fehlannahme. Tatsächlich zeigt sich das Problem der Sprachverarbeitung als große Herausforderung für die KI, da natürliche Sprachen nur mit viel Hintergrundwissen korrekt interpretiert werden können.

Spielprobleme geringer Problemgrößen ließen sich durch das Erzeugen aller möglichen Spielkonfigurationen, das Abspeichern in Baumstrukturen und das anschließende Absuchen nach einer gültigen Lösung gut bewältigen. Doch weitaus komplexere Probleme der realen Welt überstiegen die Leistung solcher einfachen Strategien bei weitem (Ertel 2016, vgl. S. 9). Dass eine einfache Skalierung nicht ausreichte, um eine Lösungsstrategie kleiner Probleme auf gleichartige, größere Probleme anzuwenden, zeigte die Entwicklung der Komplexitätstheorie durch Hartmanis und Stearns (1965) mit den Grenzen der Such- und Traversierungsalgorithmen. So bedarf die Lösung für das so genannte 8-Puzzle bei einer Problemgröße eines 3x3 Felds mit acht Spielsteinen wenige Sekunden zur Lösung. Das gleiche Rätsel der Feldgröße 5x5 benötigt jedoch Stunden zur Lösung selbst auf schnellen Rechnern. Der Grund dafür liegt darin, dass das Spielproblem NP-vollständig ist und sich somit nichtdeterministisch in Polynomialzeit

lösen lässt.

Selbst die inzwischen erfolgreich eingesetzte Theorie der genetischen Algorithmen, bei denen zufällige *Mutationen* genannte Veränderungen und Kreuzungen, genannt *Cross-Over*, die Varietät der Lösungen erhöhen und so zu neuen Erkenntnissen führen sollten, ergab in der damals einfachen Form selbst mit hohem Rechenaufwand kaum nennenswerte Resultate (Weicker 2015, vgl. S. 10f). Es wurde evident, dass den Methoden der KI-Forschung deutliche Grenzen gesetzt waren.

A.2.1.6. Wissen als Basis neuer Systeme

In den 1970er Jahren erbrachten vor allem *Expertensysteme* für den chemischen und medizinischen Einsatz einen großen Nutzen. Erstmals verfolgten KI-Forscher den Ansatz, von den generellen Lösungen aus Suchen und Traversierungen vollständiger Bäumen abzurücken. Stattdessen bezogen neue Ansätze das Wissen über die Einsatzdomäne ein.

So erarbeitete das Programm *DENDRAL* nach Feigenbaum und Buchanan (1971, vgl. S. 40) neue Heuristiken, bei denen Spitzen in einem Massenspektrum dazu genützt werden, bestimmte Unterstrukturen in gegebenen Molekülen zu erschließen und so den Suchaufwand um ein Vielfaches zu verringern. Nach Russell und Norvig (2012, S. 46) war *DENDRAL* ein „frühes Beispiel für diesen Ansatz“, bei welchem „[d]ie Erkenntnis, dass das Molekül eine bestimmte Unterstruktur enthält, [...] die Anzahl der möglichen Kandidaten wesentlich [reduziert]“. Schnell erkannten KI-Forscher, dass so genannte *Expertensysteme* mit einer starken Wissensbasis Probleme weit effizienter lösen konnten als allgemeine Ansätze.

A.2.1.7. Renaissance der neuronalen Netze

Durch den Sammelband *Parallel Distributed Processing* von Rumelhart und McClelland (1987) erlebte das Konzept der neuronalen Netze, wie sie bereits durch McCulloch und Pitts (1943) erdacht wurden, einen neuen Aufschwung. In dem Werk *Parallel Distributed Processing* wird beschrieben, dass „[d]as Gewicht der Verbindungen zwischen Recheneinheiten Wissen darüber abbilden, wie Dinge einer bestimmten Domäne zusammenhängen und die Substrukturen der Initialdaten Fragmente einer Struktur innerhalb der Domäne darstellen. [...] Das Netzwerk berechnet eine *gute Lösung* zum Problem, indem es die Zustände der Recheneinheiten andauernd aktualisiert [...], bis das Netzwerk letztendlich einen stabilen Zustand annimmt und so

die Lösung gefunden ist“ (Rumelhart und McClelland 1987, S. 282).

Bei dem Sammelband handelte es sich um umfangreiche empirische Untersuchungen anhand des *Backpropagation-Algorithmus*, bei dem Approximationsaufgaben effizient gelöst werden können. Der *Backpropagation-Algorithmus* ging aus der inkrementellen Delta-Regel hervor und wird für das überwachte Lernen von neuronalen Netzen genutzt. Die Delta-Regel ist ein Gradientenverfahren, bei dem durch fortlaufende Wiederholungen der Eingaben eine Optimierung der Verbindungsstärken stattfindet. Ein so genannter Lehrer kennt beim Backpropagation-Algorithmus für jede Eingabe die gewünschte Ausgabe. Die Möglichkeit, dass ein so gelerntes Netz über mehrere Schichten verfügen konnte, ermöglichte durch Abstraktion eine weitreichende Mustererkennung (Ertel 2016, vgl. S. 291).

A.2.1.8. Daten werden wertvoller als Speicher

Vor allem die auch weiterhin große Herausforderung korrekter Übersetzungen natürlicher Sprachen erforderte ein grundlegendes Umdenken in der linguistischen KI-Forschung. Als kurz nach der Jahrtausendwende die Speicher kostengünstiger wurden und sich auch das Internet so weit etabliert hatte, dass mit sehr großen Datenmengen geforscht werden konnte, stellte sich heraus, dass es für manche Probleme sinnvoller erschien, sich weniger Gedanken um eine algorithmische Lösung zu machen, als vielmehr die Zusammensetzung von gleichartigen Daten als Weg zur Wissensgewinnung zu nutzen.

So wird in (Russell und Norvig 2012, S. 52) am Beispiel des englischen Worts „plant“ veranschaulicht, dass die Übersetzung dieses Worts grundverschieden ausfallen kann. Es steht zum einen für eine Pflanze, kann das Einpflanzen bedeuten, aber auch das Hinterlegen von etwas oder gar Fabrik. Welche Übersetzung richtig ist, lässt sich aus dem Kontext erschließen. Verlässt sich ein Algorithmus darauf, dass das Aufkommen von Wörtern vor und nach dem Begriff „plant“ stets eine ähnliche Übersetzung zur Folge hat, besticht die Lösung mit erstaunlicher Korrektheit. So ist die Wahrscheinlichkeit, dass es bei dem vorgelagerten Wort „nuclear“ um eine Pflanze geht, sehr gering (aber nicht undenkbar). Viel häufiger ist jedoch die Übersetzung als „nuclear plant“ und somit als Atomkraftwerk. Linguisten waren zu Beginn solcher Vorgehensweisen empört und waren überzeugt davon, dass nur ein regelbasiertes System gut übersetzen könne. Der Erfolg von datenbasierten Übersetzern wie *Google Translate* bezeugen jedoch die Wirksamkeit des Lösungswegs.

Die Währung der digitalen Welt sind Daten. Scholz (2016, S. 25) bemerkt, dass Big Data

allgemeinhin als Synonym für Wirtschaftlichkeit stehe. Nicht nur für Anwendungsbereiche wie die Wirtschaftspsychologie oder Unternehmensstrategie ist das heutige Datenaufkommen zum Kern einiger Geschäftstätigkeiten geworden. Auch die modernen Verfahren der Künstlichen Intelligenz wie neuronale Netze, lernende Agenten oder probabilistische Expertensysteme auf Basis von Bayesschen Netzen sind auf eine große Menge von Daten zwingend angewiesen. Erst die digitale Revolution ermöglichte völlig neue Ansätze unlängst bekannter Methoden.

A.2.2. Paradigmen der Arbeitspsychologie

Die Studieneignungsdiagnostik und die Arbeitspsychologie sind eng verwandt. Die Entwicklungen in der Arbeitspsychologie und der aktuelle Erkenntnisstand haben sich auch auf die Studieneignungsdiagnostik ausgewirkt. Die Arbeitspsychologie hat im Verlauf eines Jahrhunderts dramatische Veränderungen erfahren. Diese Dynamik kann als deutlicher Paradigmenwechsel vom Menschen als Maschine hin zu einem Verständnis des Menschen als soziales Wesen mit starker Wechselwirkung zu gesellschaftlichen Gruppen beschrieben werden. Davon geprägt ist die moderne Eignungsdiagnostik, die mehr und mehr davon abrückt, nur auf schulische oder akademische Noten als Leistungsbeleg zu setzen. Der Paradigmenwechsel der Arbeitspsychologie wird nachfolgend beschrieben, um im Anschluss daran die Liberalisierung im Hochschulgesetz zur Studierendenauswahl zu skizzieren.

A.2.2.1. Die Anfänge der Eignungsdiagnostik: Münsterbergs Industrielle Psychotechnik

Die Psychotechnik war ab 1903 eine von William Stern erdachte Disziplin, die zum Ziel hatte, die Lebensbereiche zu optimieren. Der breiten Öffentlichkeit bekannt gemacht hat der Psychologe Hugo Münsterberg die so genannte *Industrielle Psychotechnik* als Teildisziplin der ursprünglichen Psychotechnik. Münsterberg definierte diese als „Wissenschaft von der praktischen Anwendung der Psychologie im Dienste der Kulturaufgaben“ (Münsterberg 1914, S. 1). Zitierweise inkonsistent Als historisch erste Psychologie befasste sich die Psychotechnik mit den Fragen nach Berufseignung und ökonomischem Nutzen psychologischer Erkenntnisse und Methoden.

Die Psychotechnik traf die Grundannahme, dass die planmäßige und systematische Berücksichtigung von psychologischen Faktoren die Effizienz und Kostenoptimierung einer Arbeitskraft weit erhöhen könnte. Dabei galt das Credo, der richtige Arbeitnehmer für einen vorgegebenen

Arbeitsplatz müsse ausfindig gemacht werden. Eignungsdiagnostisch hieß dies, vor allem durch häufig durchgeführte Tests die Leistung kontinuierlich zu dokumentieren und gegebenenfalls personelle Konsequenzen zu ziehen. Dabei befasste sich Münsterberg bereits 1912 mit Themenbereichen wie der Eignung und Auslese, Übungen und Lernen, aber auch mit Monotonie und Ermüdung (Ulich 2011, Vgl. S. 16ff).

A.2.2.2. Scientific Management und die Bedeutung des Nationalsozialismus für die moderne Eignungsdiagnostik

Eine parallel zur Psychotechnik war das 1911 entwickelte Konzept des *Scientific Management* durch den Ingenieur Frederick Winslow Taylor. In seinem Werk zum Scientific Management beschreibt Taylor, dass der Mensch im Grunde egoistisch sei und stets nach Gewinnmaximierung bei geringstmöglichem Einsatz strebe. Die Natur des Menschen sei Bequemlichkeit. Daher sei ein Arbeitgeber nicht am Unternehmensziel interessiert und müsse durch strikte Kontrolle und gütige Leistungsboni durch die Betriebsleitung für die Arbeit motiviert werden.

Um das Gelingen der Unternehmung weg vom einzelnen Arbeiter als egoistisches und faules Wirtschaftssubjekt hin zum lenkenden Management zu bewegen, schlug Taylor vor, die Arbeit in möglichst kleine, atomare Arbeitsschritte zu unterteilen, die ein ungebildeter Arbeiter zügig bewältigen könne. Ferner forderte Taylor, die Planung und Ausführung der Arbeit zu trennen, sodass der Erfolg einer Unternehmung einzig vom Management gelenkt werden könne. Taylor sah ein übermäßig großes tägliches Arbeitspensum als Motivation für die Arbeiter. Fleiß sollte belohnt werden, Unterbietung der Arbeitsleistung bestraft (Taylor 2011, Nachdruck von 1912. Vgl. S. 25ff). Diese Vorgehensweise wurde später von den Nationalsozialisten umfänglich eingesetzt und geriet somit deutlich in Verruf.

A.2.2.3. Der Mensch als konditionierbares Wirtschaftssubjekt

Der Behaviorismus nahm seine Anfänge mit dem Psychologen John B. Watson und dessen im bedeutenden *Journal of Experimental Psychology* beschriebenen Experiment vom *Kleinen Albert* (Association 2013, Nachdruck von 1920. Vgl. S. 1 - 14). Bei diesem Experiment wurde hinter einem Säugling stets auf einen Metallbarren geschlagen, wenn dieser einen kuschligen, haarigen Hasen berührte. Nach einigen Durchführungen zeigte der Säugling auch ohne Barrenschläge Angsterscheinungen, wann immer er etwas Haariges berührte. Die Psychologen entdeckten, dass der *Kleine Albert* konditioniert worden war.

Auch das Experiment von Ivan Pavlov festigte diese Erkenntnis. Den so genannten Pavlov'schen Hunden wurden Apparaturen zur Messung des Speichelflusses chirurgisch angebracht. Anschließend wurde vor jeder Fütterung eine Glocke geschlagen. Stets entwickelten die Hunde beim Klang der Glocke Speichelfluss. Nach einigen Durchgängen entstand dieser Speichelfluss selbst dann, wenn es im Anschluss an den Glockenschlag gar kein Futter gab. Die Hunde wurden *konditioniert* (Pavlov 1928, Vgl. S. 13ff). Die konditionierte Reaktion wird definiert als „Reaktion, hervorgerufen von einem initial neutralen Stimulus, das in Verbindung gebracht wurde mit einem unkonditionierten Stimulus, welcher normalerweise diese Reaktion erzeugt“ (Collin u. a. 2012, Aus dem Englischen, S. 340).

Aus diesen beiden und weiteren Experimenten entstand die Lehre, die sich *Behaviorismus* nennt. Definiert wird diese Lehre als „eine psychologische Herangehensweise, dass nur beobachtbare Verhaltensmerkmale untersucht werden sollen, sodass diese Verhaltensweisen objektiv beobachtet, beschrieben und gemessen werden können“ (ebd., Aus dem Englischen. S. 340). Diese Definition schließt somit sämtliche Introspektionen, d.h. *nach innen* gerichteten Beobachtungen, aus.

A.2.2.4. Schwachstellen der klassischen Leistungsbewertung: Psychosoziale Faktoren als ungeahnt wertvolle Indikatoren

Der Behaviorismus verlangt, die Introspektion außer Acht zu lassen. Eine wichtige Entdeckung zeigte jedoch bereits 1924, also kurz nach den Anfängen des Behaviorismus im Jahr 1920, dass diese Grundannahme falsch war. Der australische Psychologe Elton Mayo führte in den 1930er Jahren ein mehrjähriges Experiment in den Hawthorne Elektrizitätswerken mit sechs Probandinnen durch. Dabei sollte ursprünglich die Auswirkung der Arbeitsumgebung, wie beispielsweise das Lichtverhältnis, auf die Arbeitsleistung untersucht werden. Als allerdings selbst die Kontrollgruppe ohne Verbesserungen ebenfalls weit gesteigerte Effizienz zeigte, wurde der so genannte Hawthorne-Effekt entdeckt. Die Kontrollgruppe steigerte demnach nur deshalb die Effizienz, weil die Probandinnen wussten, dass sie beobachtet wurden. Als Mitglied eines sozialen Geflechts war es den Arbeiterinnen wichtig, von ihren Kolleginnen als tüchtig wahrgenommen zu werden. Damit waren sowohl der Taylorismus als auch der Behaviorismus grundlegend in Frage gestellt (ebd., Vgl. S. 335).

Vor allem die enttäuschenden Ergebnisse des in der Nachkriegszeit weit adaptierten Taylorismus zwang die Arbeitspsychologie in den 1960er und 1970er Jahren in die Humanisierung der Arbeitswelt. Wie schon durch den Hawthorne-Effekt angedeutet, sank die Produktion von

Arbeitern in tayloristischen Betrieben rasch aufgrund von persönlichem Desinteresse am Erfolg des Unternehmens und der Kollegen sowie aufgrund von Ermüdungs- und Erschöpfungsercheinungen derart, dass die anfänglichen Mehrleistungen irrelevant erschienen. Ansätze, die Arbeiter als Individuen in einem starken, sozialen Gefüge zu verstehen, erbrachten weit höhere Produktivitäten. Dies spiegelte ferner den Zeitgeist der 1970er Jahre wider, soziale Strukturen zu fördern (Collin u. a. 2012, Vgl. S. 240f).

A.2.2.5. Ego-Involvement und Big Data als Schlagwort der Zukunft

Im aktuellen Referenzwerk der modernen Eignungsdiagnostik von Sarges und Scheffer (2008) wird im Leitartikel *Ego-Involvement - ein vernachlässigtes Prinzip der Eignungsdiagnostik* daran appelliert das Ego-Involvement als zukunftsweisenden Indikator der Eignungsdiagnostik zu verstehen. Mit Ego-Involvement ist die „Betroffenheit einer Person durch Relevanz der Stimuli für die eigene Selbstidentität“ (ebd., Angelehnt an Sherif(1966)) gemeint.

Neben der modernen Auffassung, rein intellektuellen Eignungsindikatoren wie z.B. die Notenvergabe durch allgemeinbildende Schulen zumindest nicht ohne psychosoziale Indikatoren zu begegnen, erlebt die moderne Eignungsdiagnostik einen Aufschwung durch neue Möglichkeiten der Datenverarbeitung. So können große Datenbestände zu Probanden automatisiert erfasst und durch neuartige Verfahren ausgewertet werden. Neuronale Netze und Expertensysteme, wie sie eingangs in Unterabschnitt A.2.1 beschrieben wurden, finden sich im aktuellen Aufsatz *Eignungsdiagnostische Prognosen mittels Künstlicher Neuronaler Netze* wieder (ebd., Vgl. S. 363ff). Dies stellt die interdisziplinäre Schnittstelle dieser Arbeit dar, die in Kapitel 4 und Kapitel 5 thematisiert wird.

A.3. Vollständige Testdatensätze

In diesem Abschnitt befindet sich eine lange Tabelle mit allen Testdatensätzen und Vergleichsdatsätzen, die zur Untersuchung in Abschnitt 5.3 genutzt wurden. Es wurden einzig die Testdatensätze 1, 4, 8 und 11 für die Untersuchung genutzt. Die übrigen Testdaten dienen lediglich als Vergleich, um Zufälle und *Querschläger* weitestgehend ausschließen zu können.

A.3. Vollständige Testdatensätze

#	id	geschlecht	deutsch_abi	englisch_abi
1	9290	m	10,75	11,50
2	9000	m	13,75	11,75
3	4473	w	13,25	12,50
4	3259	m	13,00	11,00
5	5538	w	9,25	8,75
6	3636	m	11,50	12,25
7	3075	m	10,00	6,67
8	12321	m	12,75	9,75
9	5043	w	9,50	11,50
10	2483	m	6,50	8,75
11	4388	m	6,50	5,00
12	4894	m	9,75	10,50

#	mathe_abi	englisch_nak_test	mix_leistung	mix_bindung
1	14,00	0,87	23,00	51,00
2	14,75	0,53	57,00	88,00
3	14,25	0,73	70,00	69,00
4	15,00	0,27	31,00	51,00
5	14,75	0,60	80,00	51,00
6	14,25	0,47	70,00	69,00
7	9,33	0,47	46,00	51,00
8	8,50	0,87	75,00	84,00
9	9,00	0,67	31,00	88,00
10	8,25	0,53	89,00	88,00
11	7,50	0,40	57,00	51,00
12	7,50	0,40	80,00	29,00

#	mix_macht	iqt_sprache	iqt_merkfaehigkeit	iqt_logik
1	43,00	89,00	52,00	96,00
2	27,00	55,00	99,00	82,00
3	71,00	68,00	52,00	76,00
4	27,00	44,00	52,00	70,00
5	43,00	68,00	99,00	76,00

A.3. Vollständige Testdatensätze

#	mix_macht	iqt_sprache	iqt_merkfaehigkeit	iqt_logik
6	27,00	89,00	76,00	88,00
7	43,00	68,00	93,00	76,00
8	27,00	44,00	52,00	76,00
9	43,00	95,00	52,00	70,00
10	11,00	95,00	76,00	88,00
11	27,00	17,00	29,00	36,00
12	71,00	78,00	76,00	70,00

#	iqt_rechnen	iqt_technik	viq_s	viq_n
1	99,00	94,00	0,43	0,07
2	87,00	96,00	1,29	0,74
3	98,00	52,00	-1,27	1,42
4	87,00	52,00	-0,41	1,42
5	87,00	94,00	1,30	-1,26
6	92,00	94,00	-0,41	-0,59
7	87,00	52,00	1,30	-0,59
8	87,00	52,00	1,28	0,74
9	96,00	70,00	0,44	0,75
10	96,00	70,00	1,30	-0,59
11	39,00	89,00	1,30	1,42
12	96,00	60,00	0,44	1,42

#	viq_t	viq_f	viq_j	viq_e
1	1,96	0,32	0,9	0,5
2	1,96	-0,7	0,16	0,3
3	1,43	-1,15	0,54	0,89
4	2,02	1,37	-1,09	0,14
5	1,43	-1,15	-0,88	0,89
6	1,43	1,37	-0,88	-2,09
7	2,02	0,86	-0,07	0,89
8	1,9	-1,37	0,93	0,83
9	-0,33	1,37	-0,07	-2,09
10	0,84	-1,15	3,78	0,89

#	viq_t	viq_f	viq_j	viq_e
11	0,84	-1,15	0,13	0,89
12	1,43	-0,15	0,13	0,14

#	mathe_nak_test	mathe1_modul	mathe2_modul	programmierung_modul
1	90,00	-1,99	-1,51	-0,93
2	100,00	-1,99	-1,51	-0,93
3	100,00	-2,26	-2,31	-0,60
4	50,00	-0,14	0,38	0,88
5	80,00	1,18	1,32	0,68
6	90,00	1,34	0,44	-1,08
7	90,00	-1,97	-1,90	-0,91
8	90,00	-1,70	-1,52	-0,26
9	80,00	-1,58	-0,86	0,25
10	90,00	2,20	1,33	0,98
11	100,00	2,20	2,23	0,36
12	90,00	2,08	2,20	-0,15

A.4. Ausgewählte Scatterplots

Für das Verständnis der Datenbasis sind Scatterplots sehr hilfreich. Da die detaillierte Betrachtung für diese Arbeit weniger sinnvoll war, wurde in Abschnitt 4.2 nur eine kleine Übersicht verschiedener Scatterplots aufgezeigt, um den *Trend* zu verdeutlichen. Hier werden ausgewählte Scatterplots im Detail gezeigt.

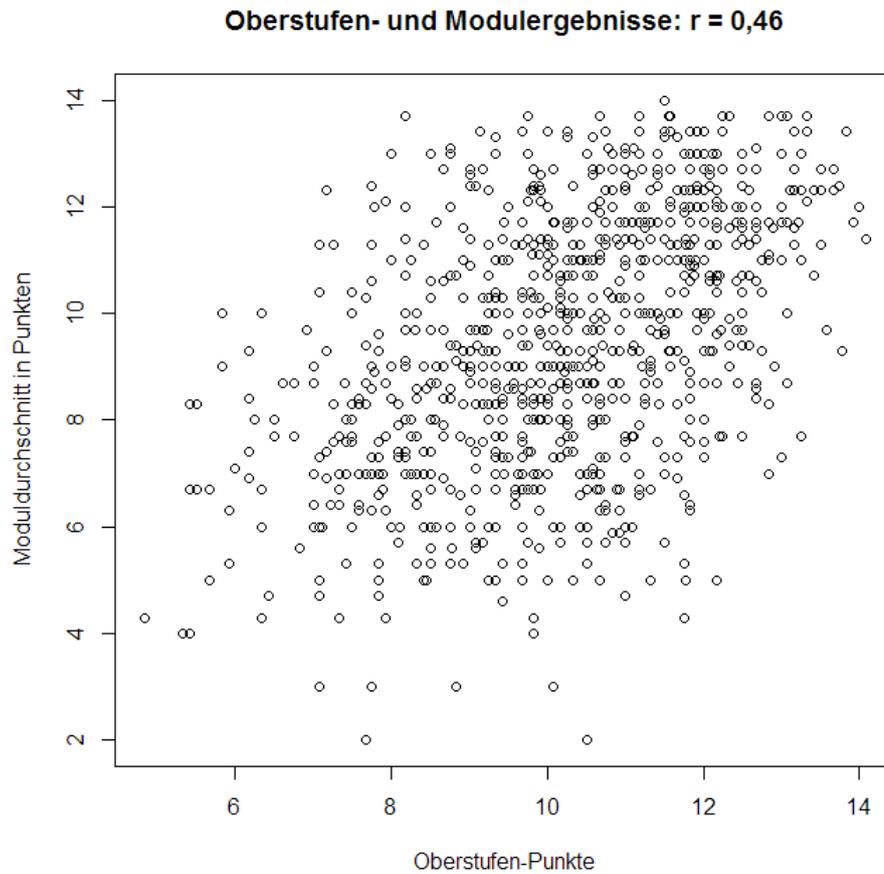


Abbildung 16.: Scatterplot der Oberstufen- und Modulergebnisse. Skalierung der Abszisse / x-Achse in Punkten [1,15]. Skalierung der Ordinate / y-Achse in Punkten [1,15]

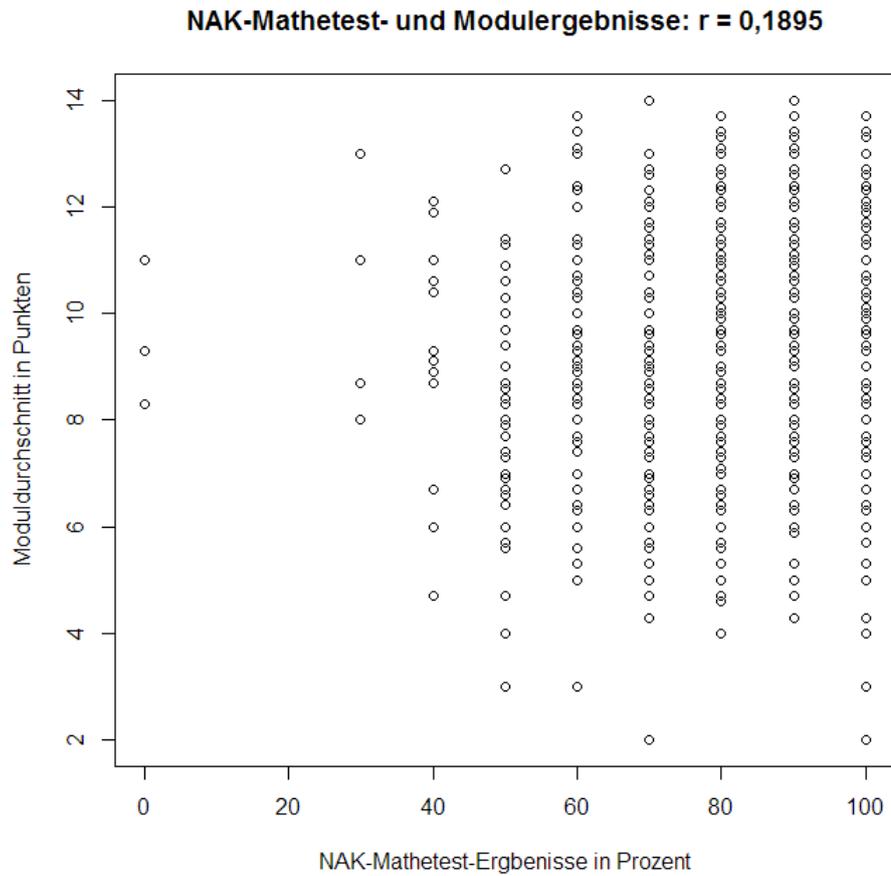


Abbildung 17.: Scatterplot Modul- und NAK-Mathematik-Test-Ergebnisse. Skalierung der Abszisse / x-Achse in Prozent. Skalierung der Ordinate / y-Achse in Punkten [1,15]

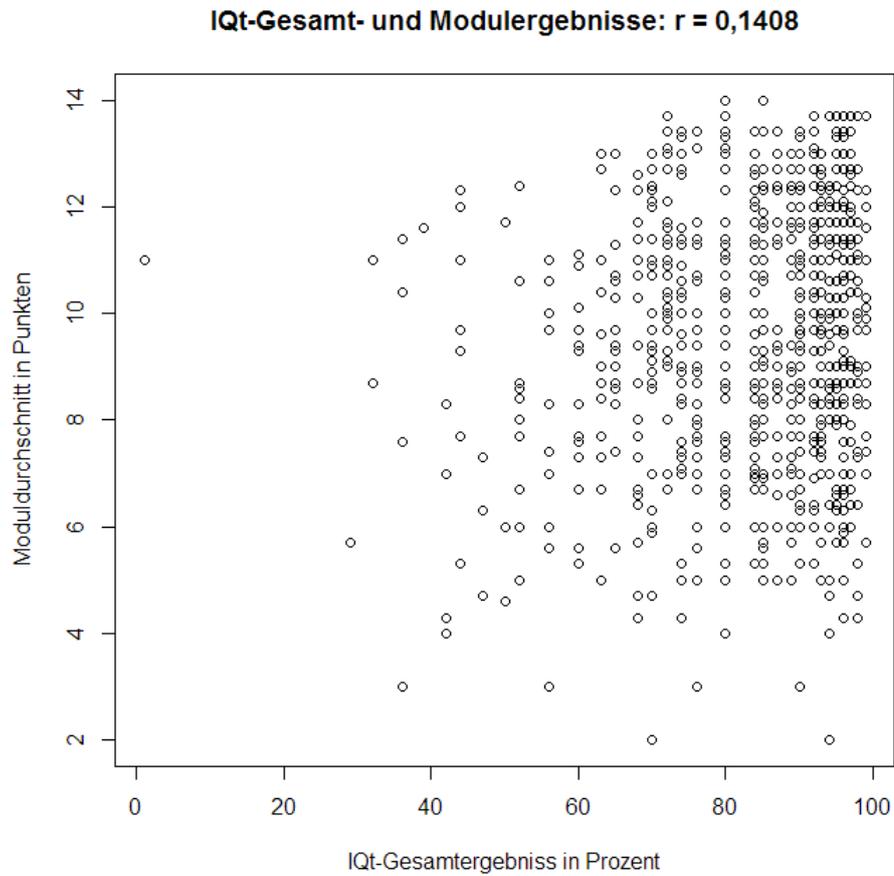


Abbildung 18.: Scatterplot der Modul- und IQT-Ergebnisse. Skalierung der Abszisse / x-Achse in Prozent. Skalierung der Ordinate / y-Achse in Punkten [1,15]

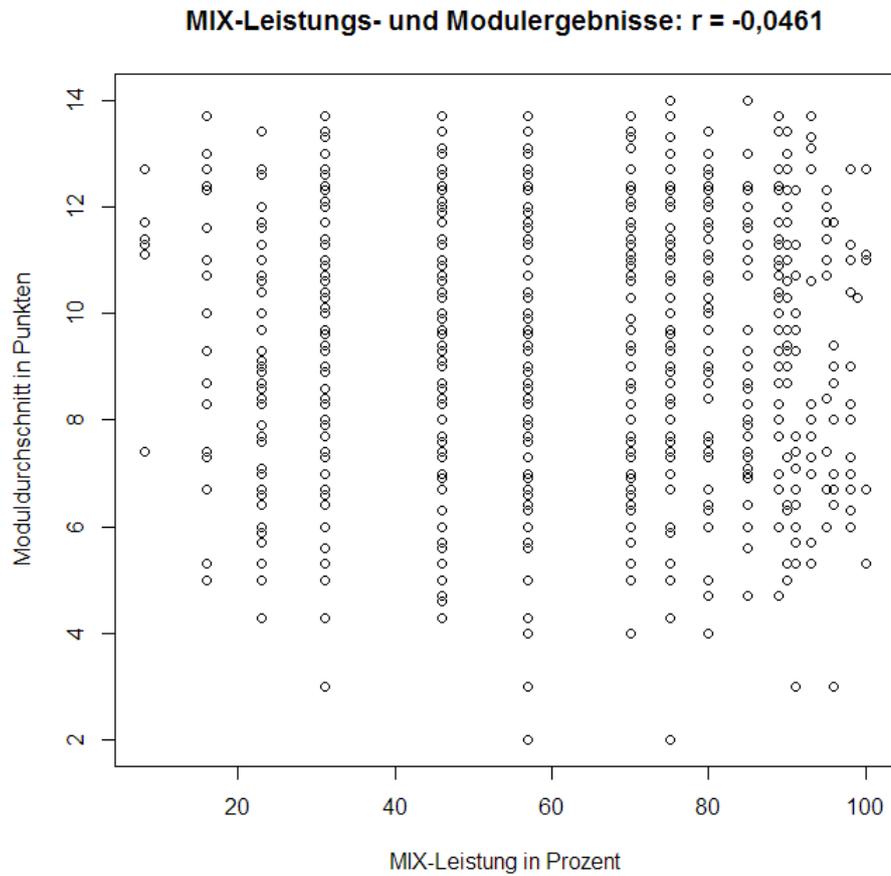


Abbildung 19.: Scatterplot Modul- und MIX-Leistungs-Ergebnisse. Skalierung der Abszisse / x-Achse in Prozent. Skalierung der Ordinate / y-Achse in Punkten [1,15]

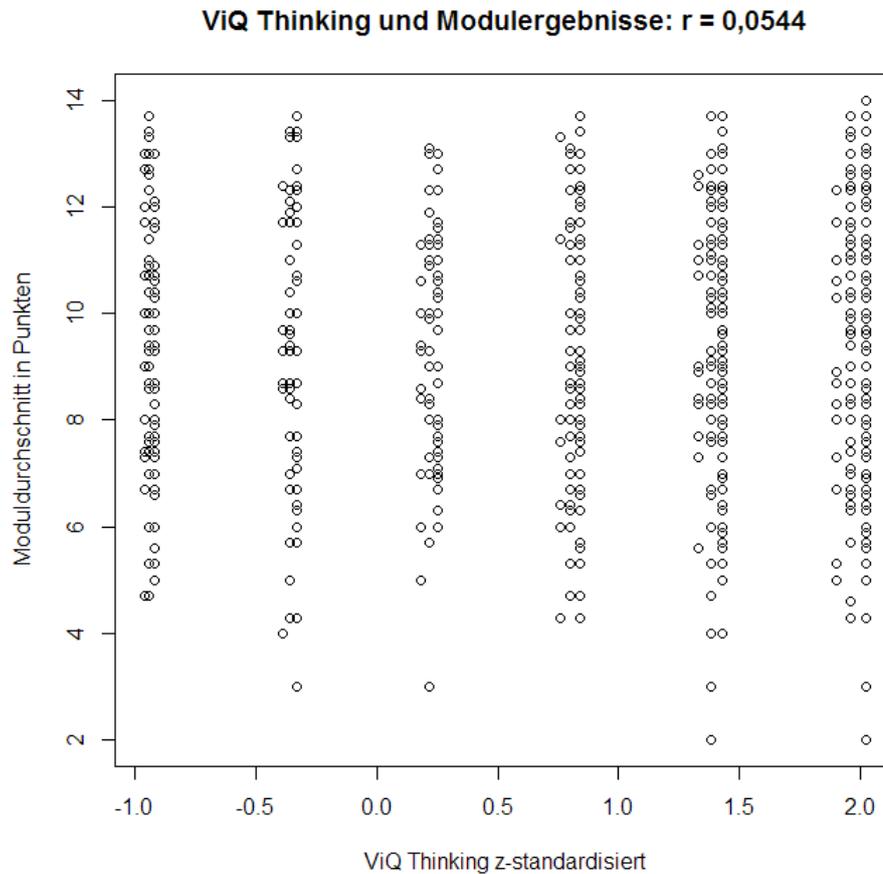


Abbildung 20.: Scatterplot Modul- und ViQ-Thinking-Ergebnisse. Skalierung der Abszisse / x-Achse z-Standardisiert [-0,96,2.02]. Skalierung der Ordinate / y-Achse in Punkten [1,15]

A.5. Korrelationstabellen

Für die Erstellung des BNs wurden Korrelationstabellen genutzt, die in der Arbeit selbst nur als kleiner Ausschnitt gezeigt werden. Zwei der insgesamt fünf Tabellenteile werden hier gezeigt, um das Prinzip noch einmal zu verdeutlichen. Die gesamte Tabelle befindet sich auf der CD in den Anlagen, zusammen mit den Scatterplots und weiteren Abbildungen.

A.5. Korrelationstabellen

	alter	deutsch_durchschnitt	englisch_durchschnitt	mathe_durchschnitt	englisch_durchschnitt
alter	1,00	-0,20	-0,19	-0,22	0,00
deutsch_durchschnitt	-0,20	1,00	0,59	0,47	0,14
englisch_durchschnitt	-0,19	0,59	1,00	0,45	0,32
mathe_durchschnitt	-0,22	0,47	0,45	1,00	0,13
englisch_durchschnitt	0,00	0,14	0,32	0,13	1,00
mix_leistung	0,07	-0,07	-0,03	0,00	0,00
mix_bindung	0,03	-0,03	-0,03	0,01	0,01
mix_macht	-0,01	0,03	0,02	-0,03	0,05
iqt_sprache	-0,05	0,09	0,09	0,10	0,20
iqt_merkfaehigkeit	0,03	0,06	-0,02	0,03	0,10
iqt_logik	0,00	0,02	0,07	0,16	0,17
iqt_rechnen	0,00	-0,01	-0,04	0,04	0,13
iqt_technik	0,02	-0,02	0,01	0,11	0,07
viq_s	0,08	-0,10	-0,09	-0,02	-0,04
viq_n	0,00	0,00	-0,04	0,05	-0,02
viq_t	-0,03	0,08	0,07	0,11	0,06
viq_f	-0,10	0,07	0,07	0,06	0,05
viq_j	0,04	-0,07	-0,07	-0,03	-0,02
viq_e	0,08	-0,07	-0,06	-0,02	-0,04
mathe	-0,05	0,07	0,09	0,19	0,20
mathe1_punkte	-0,14	0,29	0,27	0,41	0,20
mathe2_punkte	-0,16	0,31	0,31	0,42	0,15
progr1_punkte	-0,10	0,22	0,24	0,24	0,13
geschlecht	0,01	-0,19	-0,14	-0,08	-0,07

Abbildung 21.: Erster Ausschnitt der Korrelationstabelle

	mix_leistung	mix_bindung	mix_macht	iqt_sprache
alter	0,07	0,03	-0,01	-0,05
deutsch_durch	-0,07	-0,03	0,03	0,09
englisch_durch	-0,03	-0,03	0,02	0,09
mathe_durch	0,00	0,01	-0,03	0,10
englisch_durch	0,00	0,01	0,05	0,20
mix_leistung	1,00	0,31	0,33	0,06
mix_bindung	0,31	1,00	0,11	0,01
mix_macht	0,33	0,11	1,00	0,13
iqt_sprache	0,06	0,01	0,13	1,00
iqt_merkfaeh	0,03	0,01	0,04	0,12
iqt_logik	0,10	0,04	0,05	0,37
iqt_rechnen	0,03	0,05	0,07	0,10
iqt_technik	0,13	0,10	0,05	0,24
viq_s	0,01	0,03	-0,01	-0,02
viq_n	0,07	0,05	0,01	-0,02
viq_t	-0,04	0,04	-0,05	0,07
viq_f	-0,05	0,03	-0,01	0,05
viq_j	0,02	0,01	0,03	0,02
viq_e	0,02	-0,01	-0,03	-0,02
mathe	0,06	0,03	0,03	0,17
mathe1_punkt	-0,04	-0,01	-0,04	0,08
mathe2_punkt	-0,04	0,00	0,02	0,05
progr1_punkt	-0,03	0,00	0,00	0,09
geschlecht	0,06	-0,01	0,00	0,00

Abbildung 22.: Zweiter Ausschnitt der Korrelationstabelle

A.6. Beispielrechnung zu einem Bayesschen Netz

Das Nachfolgende Beispiel ist dem Fachbuch der Autoren Russell und Norvig (2012, S. 604) entnommen und war Gegenstand der Vorlesung „Methoden und Anwendungen der verteilten künstlichen Intelligenz“ an der Nordakademie Graduate School durch den Dozenten Dr. Christoph Stahl, dessen Rechenweg hier aufgeführt wird. Es dient der Veranschaulichung einer Rechenanweisung zur Bestimmung bedingter Wahrscheinlichkeiten in Bayesschen Netzen.

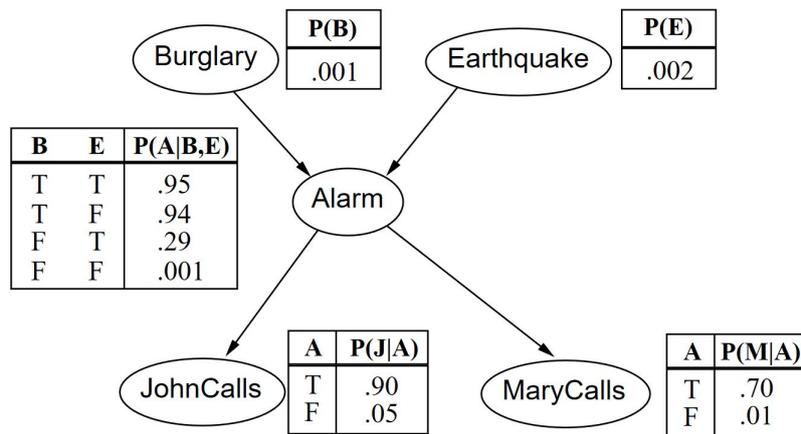


Abbildung 23.: Beispiel eines Bayesschen Netzes. Quelle: Russell und Norvig (2012, S. 604)

Betrachtet wird das Bayessche Netz auf Abbildung 23. Es wird die bedingte Wahrscheinlichkeit gesucht für ein Erdbeben, falls der Alarm läutet und sowohl John als auch Mary den Eigentümer anrufen.

Beobachtete Effekte: A=true, John=true, Mary=true; kurz a,j,m. Über einen möglichen Einbruch B ist nichts bekannt. Gesucht wird die Wahrscheinlichkeit, dass ein Erdbeben (E=true, kurz e) die Ursache für die beobachteten Effekte ist:

$$P(e|a, j, m)$$

Anwendung der Bayesschen Regel liefert

$$\frac{P(a, j, m|e)P(e)}{P(a, j, m)}$$

Durch Anwendung der Produktregel folgt

$$\frac{\frac{P(e,a,j,m)}{P(e)} P(e)}{P(a, j, m)}$$

Jetzt müssen im Zähler beide Möglichkeiten für einen Einbruch (B=true und B=false) berücksichtigt werden, indem aufsummiert wird:

$$\frac{P(b, e, a, j, m) + P(\neg b, e, a, j, m)}{P(a, j, m)}$$

Beide Summanden lassen sich nun berechnen als das Produkt aller Knoten im Netz:

$$P(b) * P(e) * P(a|b, e) * P(j|a) * P(m|a) + P(\neg b) * P(e) * P(a|\neg b, e) * P(j|a) * P(m|a)$$

Die Wahrscheinlichkeiten können aus den Tabellen des Netzes in Abbildung 23 wie folgt abgelesen werden, wobei gemäß Kolmogorov-Axiomen gilt: $P(\neg B) = 1 - P(B)$:

$$\begin{aligned} &= 0,001 * 0,002 * 0,95 * 0,9 * 0,7 + 0,999 * 0,002 * 0,29 * 0,9 * 0,7 \\ &= 0,000001197 + 0,0003650346 = 0,0003662316 \end{aligned}$$

Analog wird mit dem Nenner verfahren, mit allen Möglichkeiten für B und E:

$$\begin{aligned} P(a, j, m) &= P(b, e, a, j, m) + P(\neg b, e, a, j, m) + P(b, \neg e, a, j, m) + P(\neg b, \neg e, a, j, m) \\ &= 0,000001197 + 0,0003650346 + 0,0005910156 + 0,00062811126 = 0,00158535846 \end{aligned}$$

Letztlich werden beide Summen dividiert und damit kann die Wahrscheinlichkeit bestimmt werden:

$$P(e|a, j, m) = \frac{0,0003662316}{0,00158535846} = 0,231 = 23\%$$

A.7. Code-Listings

Nachfolgend befinden sich zwei Code-Listings. Das erste wurde tatsächlich für die Erstellung des BNs eingesetzt. Das andere wurde als Vergleichsmaß erzeugt und ist rein *händisch* – jede Verbindung wurde somit einzeln definiert. Die Verbindungen entstammen direkt den Korrelationstabellen und Experteninterviews, dienen jedoch nur dem Vergleich.

A.7.1. Erzeugung eines Bayesschen Netzes in R durch das Paket bnlearn (Hybrider Ansatz)

```
1 library(bnlearn)
2 data <- read.csv("r_data_3.csv",
3 + header = TRUE, sep = ";", na.strings=c("", "NA", " "))
4 data <- data[complete.cases(data),]
5 bn_df <- data.frame(data)
6 res <- hc(bn_df)
7
8 res <- drop.arc(res, "deutsch_abi", "iqt_sprache")
9
10 res <- reverse.arc(res, "mathe_nak_test", "iqt_rechnen")
11 res <- reverse.arc(res, "englisch_nak_test", "iqt_sprache")
12 res <- reverse.arc(res, "mix_macht", "iqt_sprache")
13 res <- reverse.arc(res, "mix_bindung", "iqt_technik")
14
15 res <- set.arc(res, "geschlecht", "programmierung_modul")
16 res <- set.arc(res, "iqt_logik", "englisch_abi")
17 res <- set.arc(res, "iqt_merkfaehigkeit", "mathe_nak_test")
18 res <- set.arc(res, "iqt_technik", "mathe_abi")
19 res <- set.arc(res, "viq_s", "deutsch_abi")
20
21 fittedbn <- bn.fit(res, data = bn_df)
```

A.7.2. Alternative BN-Erzeugung (Manueller Ansatz)

```
1 library(bnlearn)
2 data <- read.csv("r_data_3.csv",
3 + header = TRUE, sep = ";", na.strings=c("", "NA", " "))
4 data <- data[complete.cases(data),]
5 bn_df <- data.frame(data)
6 res <- hc(bn_df)
7
8 arc.set = matrix(c(
9 "alter", "mix_macht",
10 "alter", "mix_leistung",
11 "geschlecht", "mix_macht",
12 "geschlecht", "mix_bindung",
13 "mix_macht", "viq_j",
14 "mix_macht", "viq_t",
15 "mix_leistung", "viq_j",
16 "mix_leistung", "viq_s",
17 "mix_leistung", "viq_t",
18 "mix_bindung", "viq_s",
```

```
19 "mix_bindung", "viq_e",
20 "mix_bindung", "viq_f",
21 "mix_bindung", "viq_n",
22 "viq_j", "iqt_technik",
23 "viq_s", "iqt_rechnen",
24 "viq_s", "iqt_technik",
25 "viq_s", "iqt_merkfaehigkeit",
26 "viq_t", "iqt_logik",
27 "viq_e", "iqt_sprache",
28 "viq_f", "iqt_sprache",
29 "viq_n", "iqt_logik",
30 "viq_n", "iqt_sprache",
31 "iqt_rechnen", "mathe",
32 "iqt_rechnen", "mathe_durchschnitt",
33 "iqt_technik", "mathe_durchschnitt",
34 "iqt_logik", "mathe_durchschnitt",
35 "iqt_logik", "mathe2_punkte",
36 "iqt_logik", "progr1_punkte",
37 "iqt_logik", "mathe1_punkte",
38 "iqt_merkfaehigkeit", "progr1_punkte",
39 "iqt_merkfaehigkeit", "mathe1_punkte",
40 "iqt_merkfaehigkeit", "englisch_durchschnitt_abi",
41 "iqt_merkfaehigkeit", "englisch_durchschnitt_bsc",
42 "iqt_sprache", "mathe2_punkte",
43 "iqt_sprache", "deutsch_durchschnitt",
44 "iqt_sprache", "englisch_durchschnitt_abi",
45 "iqt_sprache", "englisch_durchschnitt_bsc"),
46 + ncol = 2, byrow = TRUE, dimnames = list(NULL, c("from", "
    to")))
47
48 arcs(res) = arc.set
49
50 fittedbn <- bn.fit(res, data = bn_df)
```

A.8. Leitfaden für Experteninterviews

Einleitung

Interviewleitfaden zu Experteninterviews der Masterthesis zum Thema „Predictive Analytics und Studieneignungsdiagnostik“ des Studiengangs Master of Science: Wirtschaftsinformatik / IT-Management der Nordakademie Graduate School.

Das nachfolgende Interview dient primär der Beantwortung der Frage, welche vorgefertigten Bayesschen Netze mit entsprechenden Parametern am ehesten die bedingten Abhängigkeiten abbildet und anschließend für eine empirische Untersuchung genutzt werden sollen.

Daneben geht es um Fragen nach Validität und Güte ausgewählter Modulergebnisse, Bewertung von Schulnoten als Leistungsindikatoren und der Frage nach Studienerfolg.

Personendaten

- Datum
- Name, Vorname
- Beruf
- Bezug zum Thema

Belehrung

Ich zeige mich damit einverstanden, dass die nachfolgenden Notizen sinngemäße Aussagen zu den im Interview gestellten Fragen widerspiegeln. Diese sinngemäßen Aussagen dürfen für die wissenschaftliche Arbeit ausgewertet und auszugsweise zitiert werden. Mir ist bewusst, dass die Teilnahme an dem Interview freiwillig ist und unentgeltlich stattfand. Ebenso kann ich einer Speicherung meiner Daten jederzeit widersprechen und deren Löschung verlangen.

Ich bin damit einverstanden, im besprochenen Forschungsprojekt mein Interview zu geben (zu beantworten mit 'Ja' oder 'Nein').

Vorgestelltes Informationsmaterial

- Screenshot aus ViQ
- Screenshot aus MIX
- Screenshot aus IQT
- Tabelle ausgewählter Module

- Statistische Voruntersuchung (Scatterplots, bi- und univariate Statistik)
- Korrelationstabellen
- Modell eines auf den Korrelationstabellen basierenden BNs

Fragen

- Güte von Noten als Indikatoren für die Eignung zukünftiger Softwareentwickler: Würden Sie sagen, dass Noten ein guter Indikator sind? Sollten Noten der einzige Indikator sein?
- Erscheint die Methode, sich auf Korrelationen zu fokussieren, sinnvoll?
- Würden Sie sagen, dass die bloße bivariate Statistik zu wenige Informationen als Prädiktor aufzeigt?
- Halten Sie die ausgewählten Module für repräsentativ, um eine grundlegende Befähigung zur Softwareentwicklung aufzuzeigen?
- Würden Sie bestimmte Variablen weg lassen oder andere hinzunehmen (im Bezug auf das Modell-Netz)?
- Halten Sie es für sinnvoll, 12 Datensätze mit je drei Repräsentanten einer Klasse aus Abi-Noten und Modul-Noten zu nutzen?
- Würden Sie übereinstimmen mit der Annahme, dass die MIX-Werte die IQ-Werte beeinflussen (nicht anders herum)?
- Würden Sie übereinstimmen, dass die IQ-Werte die späteren Prüfungsergebnisse beeinflussen (nicht anders herum)?
- Haben Sie zusätzliche Anmerkungen?

A.9. Hybrides Bayessches Netz im Detail

In diesem Abschnitt wird die Struktur des hybriden BNs aus der Untersuchung und dessen Arc-Strength (Verbindungsstärke) als Schaubild gezeigt. Die Arc-Strength wurde zudem durch-

nummeriert und mit einer Legende versehen. Die einzelnen Werte werden als Code-Listing aufgezeigt.

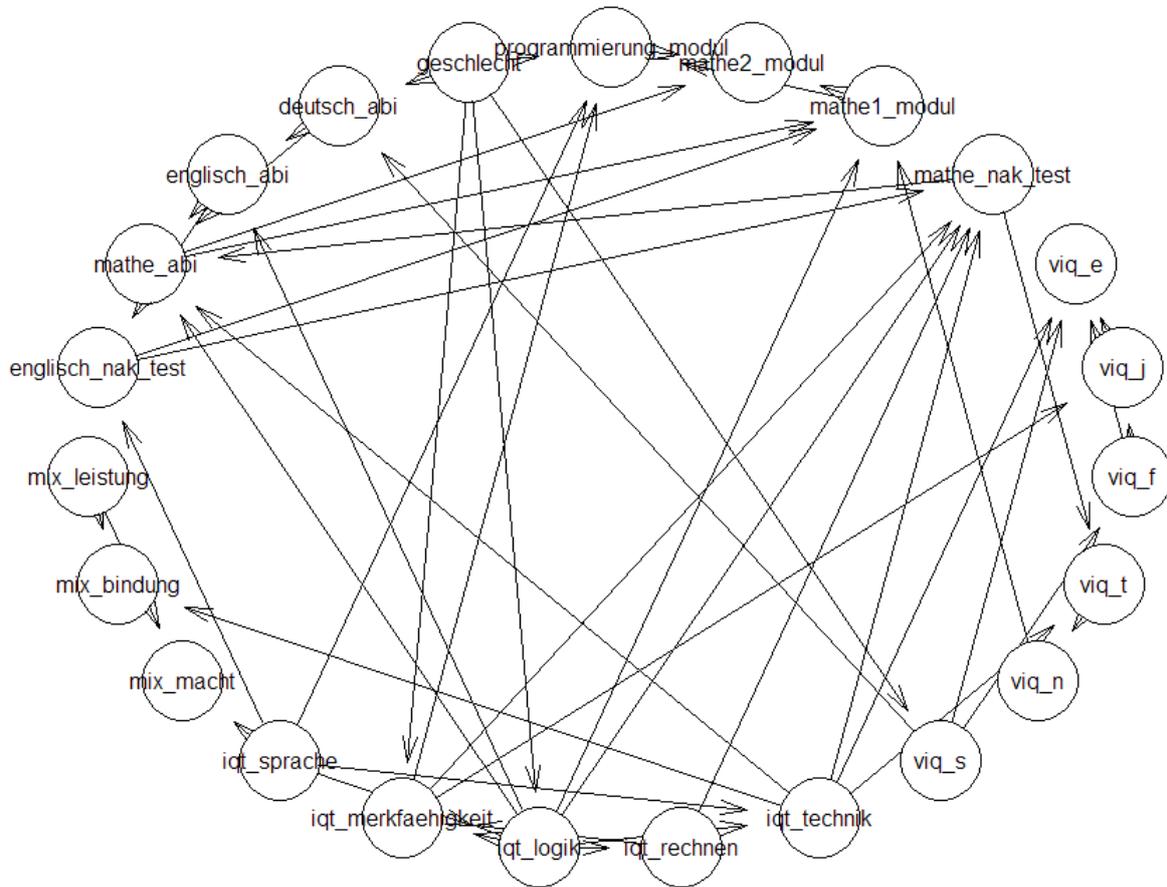


Abbildung 24.: Struktur des hybriden BNs

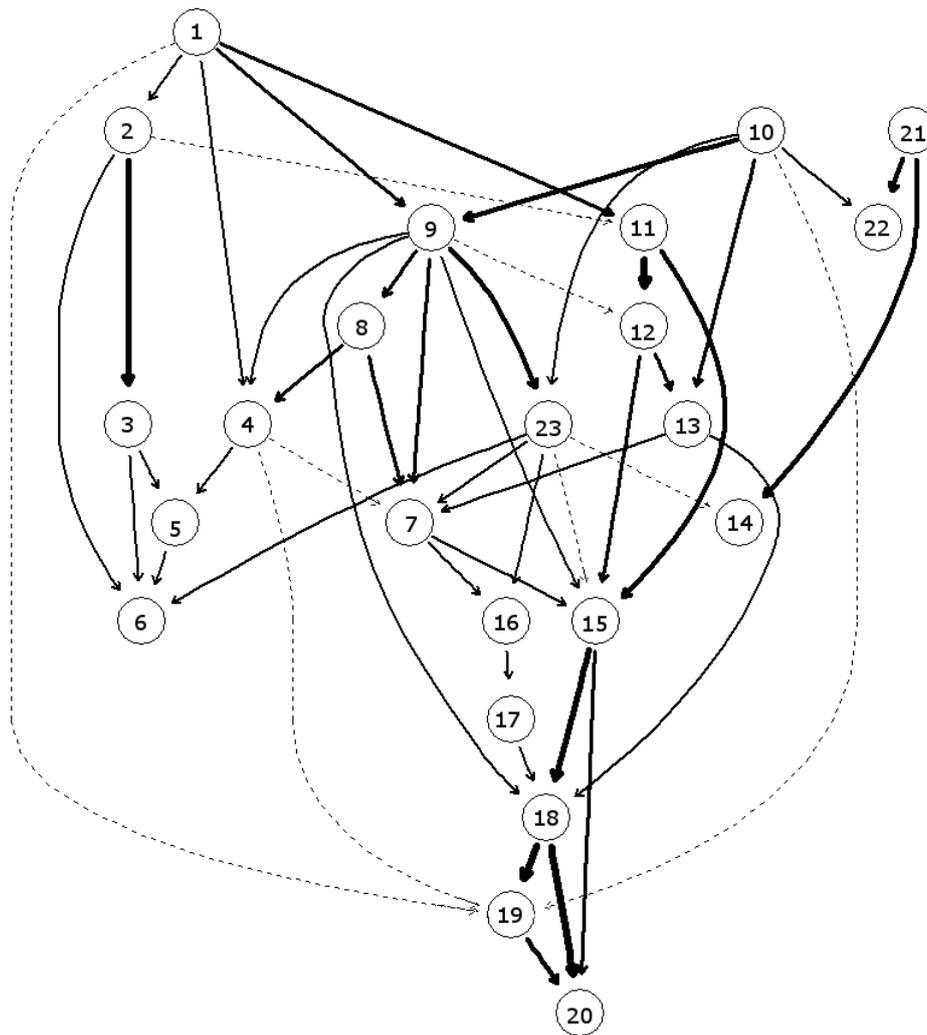


Abbildung 25.: Stärke der Arcs als Schema.

1	geschlecht	9	iqt_logik	17	viq_n
2	viq_s	10	iqt_sprache	18	mathe1_modul
3	viq_f	11	deutsch_abi	19	progr_modul
4	iqt_merkfaehigkeit	12	englisch_abi	20	mathe2_modul
5	viq_j	13	englisch_nak_test	21	mix_leistung
6	viq_e	14	mix_bindung	22	mix_macht
7	mathe_nak_test	15	mathe_abi	23	iqt_technik
8	iqt_rechnen	16	viq_t		

A.9. Hybrides Bayessches Netz im Detail

	from	to	strength
1	mathe1_modul	mathe2_modul	-123.7500451
2	deutsch_abi	englisch_abi	-283.7575987
3	deutsch_abi	mathe_abi	-55.7075973
4	iqt_logik	iqt_technik	-59.8221620
5	mathe_abi	mathe1_modul	-70.2679798
6	viq_s	viq_f	-72.7894652
7	iqt_sprache	iqt_logik	-68.7966539
8	mix_leistung	mix_macht	-51.5489510
9	mix_leistung	mix_bindung	-49.4562102
10	englisch_abi	englisch_nak_test	-40.2127354
11	iqt_logik	mathe_nak_test	-10.8640291
12	mathe1_modul	programmierung_modul	-181.7315480
13	englisch_abi	mathe_abi	-34.5664520
14	iqt_rechnen	iqt_merkfaehigkeit	-10.9972100
15	geschlecht	deutsch_abi	-11.1781019
16	viq_f	viq_e	-7.5099285
17	iqt_logik	mathe_abi	-2.1929575
18	englisch_nak_test	mathe_nak_test	-7.9157813
19	mathe_abi	mathe2_modul	-11.1984186
20	iqt_logik	iqt_rechnen	-25.3861149
21	geschlecht	iqt_logik	-8.2120521
22	iqt_logik	iqt_merkfaehigkeit	-4.5217908
23	mathe_nak_test	mathe_abi	-4.6051566
24	geschlecht	viq_s	-5.8700681
25	englisch_nak_test	mathe1_modul	-3.1828782
26	iqt_technik	mathe_nak_test	-4.7601425
27	mathe_nak_test	viq_t	-0.7176975
28	viq_j	viq_e	-3.9102869
29	iqt_technik	viq_e	-4.1957441
30	viq_s	viq_e	-3.5446737
31	iqt_sprache	iqt_technik	-2.3731633
32	iqt_logik	mathe1_modul	-1.1038145
33	geschlecht	iqt_merkfaehigkeit	-1.0477580
34	viq_n	mathe1_modul	-0.2392857
35	programmierung_modul	mathe2_modul	-50.8590716
36	iqt_sprache	programmierung_modul	1.5301476
37	iqt_merkfaehigkeit	programmierung_modul	3.5279087
38	iqt_merkfaehigkeit	viq_j	-0.2848589
39	viq_f	viq_j	-0.2728743
40	iqt_technik	viq_t	-0.5694415
41	viq_t	viq_n	-0.2734709
42	iqt_rechnen	mathe_nak_test	-18.2477845
43	iqt_sprache	englisch_nak_test	-11.1540957
44	iqt_sprache	mix_macht	-3.8048114
45	iqt_technik	mix_bindung	0.4385891

	from	to	strength
46	geschlecht	programmierung_modul	10.5575943
47	iqt_logik	englisch_abi	1.0670456
48	iqt_merkfaehigkeit	mathe_nak_test	2.7897589
49	iqt_technik	mathe_abi	0.9200351
50	viq_s	deutsch_abi	4.7726399

A.10. Modulbeschreibungen

Nachfolgend finden sich Auszüge aus den Modulhandbüchern der entsprechenden Studiengänge an der FH Nordakademie. Sie werden den Studierenden zur Verfügung gestellt und beschreiben exakt, welche Inhalte in den Modulen zu erwarten sind. Allerdings sind sie nicht frei zugänglich und werden daher auszugsweise dieser Arbeit angehängt.

A.10.1. B.Sc. Betriebswirtschaftslehre

Nachfolgend finden sich die aus dem Modulhandbuch zum Studiengang ab 2011 unverändert entnommenen Modulbeschreibungen der drei für diese Arbeit relevanten Module. Herausgegeben werden die Module intern an alle Studierenden der Nordakademie (Plate 2016c)

A.10.1.1. Wirtschaftsmathematik 1

Position im Studiengang

Das Modul vermittelt grundlegendes mathematisches Verständnis und Fähigkeiten, die eine wissenschaftliche und quantitative Betrachtungsweise in der Betriebswirtschaftslehre erst ermöglichen. Insbesondere die eher quantitativ ausgerichteten Anschlussmodule wie bspw. Controlling oder Logistik greifen auf das hier erworbene Wissen zurück. Inhaltlich wird besonderen Wert auf den ökonomischen Bezug der behandelten Aufgabenstellungen gelegt. Im sich anschließenden Modul 'Wirtschaftsmathematik 2' werden die benötigten mathematischen Fähigkeiten weiter ausgebaut. Der Lerninhalt Zinsrechnung ist Teil des Moduls 'Investition und Finanzierung'.

Qualifikations- und Modulziele

- Matrizen
- Lineare Gleichungssysteme
- Funktionen mit einer unabhängigen Variable
- Differentialrechnung
- Integralrechnung

A.10.1.2. Wirtschaftsmathematik 2

Position im Studiengang

Im Modul werden mathematische Fähigkeiten vermittelt, die eine unverzichtbare Grundlage für eine quantitative Betrachtung ökonomischer Sachverhalte darstellen. Thematisch stellt das Modul eine Erweiterung des im Modul 'Wirtschaftsmathematik 1' erworbenen Wissens dar. Die Lerninhalte werden darüber hinaus benötigt, um die Studierenden auf ein anschließendes Masterstudium vorzubereiten.

Qualifikations- und Modulziele

- Funktionen mit mehreren unabhängigen Variable
- Grundlagen der Linearen Optimierung
- Statistik

A.10.1.3. Einführung in die Datenverarbeitung

Position im Studiengang

Die Kenntnis geeigneter IT- Werkzeuge sowie deren effiziente und effektive Nutzung stellt angesichts der zunehmenden IT-Durchdringung betrieblicher Prozesse eine wichtige Kompetenz dar. Aus diesem Grund sind im Studiengang Lehrveranstaltungen vorgesehen, die IT-Inhalte aufgreifen. Das Modul 'Einführung in die Datenverarbeitung' vermittelt neben einem Überblick über die wichtigsten IT-Anwendungen im Unternehmen zunächst methodische und praktische Grundlagen zur Konzeption und zum Aufbau von Datenbanken. In der betrieblichen Praxis zeigen sich häufig die Grenzen von Standard- Anwendungssystemen, die deren aufgaben- und unternehmensspezifische Anpassung erforderlich machen. Durch die Vermittlung von Grundkenntnissen der Softwareentwicklung wird ein Verständnis für die besonderen Herausforderungen der Programmierung geschaffen, um Möglichkeiten und Grenzen besser

einzuschätzen und darauf aufbauend realistische Anforderungen an die IT formulieren zu können (deren konkreter Einsatz im Unternehmen wird im Modul 'Betriebswirtschaftliche Anwendungssysteme' verdeutlicht). Das Modul setzt fundierte Kenntnisse gängiger Tabellenkalkulationssoftware voraus, die z.B. durch Belegung eines vorbereitenden Seminars im ersten Semester erworben werden können.

Qualifikations_ und Modulziele

- Einführung in die Wirtschaftsinformatik / Einordnung in den Studiengang
- Software in Unternehmen
- Grundlagen der Entwicklung relationaler Datenbanken
- Praktische Übungen zu Datenbankanwendungen am Beispiel von Microsoft Access
- Einführung in Softwareentwicklungsprojekte
- Einführung in die Programmierung
- Entwicklung von Software für betriebswirtschaftliche Problemstellungen
- begleitende praktische Übungen

A.10.2. B.Sc. Wirtschaftsingenieurwesen

Nachfolgend finden sich die aus dem Modulhandbuch zum Studiengang ab 2011 unverändert entnommenen Modulbeschreibungen der drei für diese Arbeit relevanten Module. Herausgegeben werden die Module intern an alle Studierenden der Nordakademie (Plate 2016e)

A.10.2.1. Ingenieurmathematik

Position im Studiengang

Das Modul vermittelt ein grundlegendes mathematisches Verständnis sowie elementare Fähigkeiten, die eine wissenschaftliche und quantitative Betrachtungsweise im Bereich Wirtschaftsingenieurwesen ermöglichen. Dabei wird besonderer Wert auf den technischen sowie naturwissenschaftlichen Bezug der behandelten Aufgabenstellungen gelegt und somit das Bild des Wirtschaftsingenieurs 'geschärft'. Die Veranstaltung knüpft inhaltlich an Kenntnisse der Oberstufenmathematik an und ergänzt diese dahingehend, dass Probleme im Bereich der Ingenieurwissenschaften adäquat erfassbar und methodisch-strukturiert lösbar sind. Die

somit erlernten Fähigkeiten fungieren daraufhin als Basis für weitere technisch orientierte Module des Wirtschaftsingenieurwesens. Zur adäquaten Lösung ökonomischer Fragestellungen werden die vermittelten Kenntnisse um zusätzliche Methoden und Anwendungen im Modul 'Wirtschaftsmathematik' erweitert.

Qualifikations- und Modulziele

Qualifikationsziel: Befähigung zum wissenschaftlichen Arbeiten, zum Erkennen, Analysieren und Auswerten technischer, organisatorischer und wirtschaftlicher Zusammenhänge durch Denken in Modellen und Systemen.

Modulziel:

- Die Studierenden kennen und verstehen die grundlegenden mathematischen Begriffe der (linearen) Algebra und Analysis einer Variablen und sind in der Lage, bekannte Aufgabenstellungen in diesem Bereich zu lösen.
- Die Studierenden sind in der Lage, die vermittelten mathematischen Begriffe in einem ingenieurwissenschaftlichen Kontext anzuwenden.

Qualifikationsziel: Fähigkeit zum Lösen ingenieurwissenschaftlicher Aufgabenstellungen durch das Erlernen methodischer Arbeitsweise und das Verständnis und die Anwendung des notwendigen technischen Fachwissens.

Modulziel:

- Die Studierenden werden durch die Veranstaltung in die Lage versetzt, Aufgaben mit mathematisch technischem Hintergrund vor ihresgleichen vorzutragen.

Qualifikationsziel: Fähigkeit, Geschäftsprozesse und Unternehmensabläufe mit hohen technischen Implikationen hinsichtlich ökonomischer und technischer Randbedingungen zu analysieren, zu bewerten und neu zu gestalten.

Modulziel:

- Die Studierenden können anwendungsorientierte Aufgaben mit technisch wirtschaftlichem Hintergrund selbstständig oder im Team in mathematische Modelle übertragen und lösen.

A.10.2.2. Wirtschaftsmathematik

Positionierung im Studiengang

Das Modul vermittelt in vertiefender Form mathematisches Verständnis und Fähigkeiten, die eine wissenschaftliche und quantitative Betrachtungsweise im Bereich Wirtschaftsingenieurwesen ermöglichen. Dabei wird besonderer Wert auf den ökonomischen Bezug der behandelten Aufgabenstellungen gelegt und somit das Bild des Wirtschaftsingenieurs 'geschärft'. Die Veranstaltung knüpft inhaltlich an das Modul 'Ingenieurmathematik' an, indem die dort vermittelten Kenntnisse auf wirtschaftliche Problemstellungen Anwendung finden. Die somit erlernten Fähigkeiten fungieren daraufhin als Basis für weiterführende Module, insbesondere für solche mit wirtschaftswissenschaftlichen Schwerpunkten.

Qualifikations- und Modulziele

Qualifikationsziel: Fähigkeit zum Verständnis und zur Vorbereitung von Entscheidungen aus betriebswirtschaftlicher Sicht.

Modulziel:

- Die Studierenden werden durch die Veranstaltung in die Lage versetzt, ausgewählte ökonomische Aufgabenstellungen in Form von Optimierungsaufgaben zu formulieren und deren Lösung in der Vorbereitung von Entscheidungen einzusetzen.
- Die Studierenden kennen die Grundlagen der deskriptiven Statistik und können sie in einem betriebswirtschaftlichen oder technischen Kontext anwenden. Sie können einfache Prognosemodelle erstellen und interpretieren.

Qualifikationsziel: Befähigung zum wissenschaftlichen Arbeiten, zum Erkennen, Analysieren und Auswerten technischer, organisatorischer und wirtschaftlicher Zusammenhänge durch Denken in Modellen und Systemen.

Modulziel:

- Die Studierenden werden durch die Veranstaltung in die Lage versetzt, Lösungsalgorithmen für ausgewählte Optimierungsaufgaben mit mehreren Variablen anzuwenden.

A.10.2.3. Einführung in die Software-Entwicklung

Positionierung im Studiengang

In der betrieblichen Praxis zeigen sich häufig die Grenzen von (Standard-) Anwendungssys-

temen, wie sie im Modul 'Grundlagen der DV im Unternehmen' dargestellt werden. Solche Systeme müssen deshalb individuell angepasst werden. Durch die Vermittlung von Grundkenntnissen der Softwareentwicklung wird ein Verständnis für die besonderen Herausforderungen der Programmierung geschaffen, um Möglichkeiten und Grenzen besser einzuschätzen und darauf aufbauend realistische Anforderungen an die IT formulieren zu können. Die Vermittlung einer objektorientierten Sprache schafft eine aktuelle und solide Wissensbasis für die Anwendung niederer Programmiersprachen in dem Modul 'Informatik in Produktion und Fertigung'.

Qualifikations_ und Modulziele

Qualifikationsziel: Kenntnis der Grundlagen der Informations- und Kommunikationstechnologie sowie der technischen Informatik, Fähigkeit, Problemlösungen algorithmisch zu formulieren.

Modulziel:

- Studierende sind nach Abschluss des Moduls in der Lage, eigenständig einfache Programme in einem allgemeinen Kontext zu entwerfen, zu erstellen und zu testen. Sie verstehen ausgewählte Aspekte der internen Qualität von Programmen.

Qualifikationsziel: Soziale Kompetenz für das Arbeiten in interdisziplinären Teams und die Fähigkeit zur internationalen Tätigkeit.

Modulziel:

- Studierende haben nach Abschluss des Moduls grundlegende Kenntnisse über den Ablauf eines Software- Entwicklungsprojekts und können eine festgelegte vorbereitete Aufgabenstellung im Team bearbeiten.

A.10.3. B.Sc. Wirtschaftsinformatik

Nachfolgend finden sich die aus dem Modulhandbuch zum Studiengang ab 2011 unverändert entnommenen Modulbeschreibungen der drei für diese Arbeit relevanten Module. Herausgegeben werden die Module intern an alle Studierenden der Nordakademie (Plate 2016d)

A.10.3.1. Diskrete Mathematik 1

Positionierung im Studiengang

Das Modul ist Voraussetzung für eine wissenschaftliche Auseinandersetzung mit Informatikthemen. Es vermittelt die formalen Ausdrucksmittel, die in einem wissenschaftlichen Studiengang benötigt werden, und die grundlegenden methodischen Fähigkeiten des deduktiven Schließens. Es werden die Grundlagen des Arbeitens mit Booleschen Ausdrücken, wie sie in jeder Programmiersprache benötigt werden, vermittelt. Hierfür wird begleitend zur Vorlesung ein fakultatives Seminar mit Laborübungen angeboten.

Qualifikations- und Modulziele

Qualifikationsziel: Befähigung zum wissenschaftlichen Arbeiten und der eigenständigen Anwendung von Methoden.

Modulziel:

- Grundlagen mathematischer Begriffsbildungen, wie sie zum Verständnis wissenschaftlicher Abhandlungen der Wirtschaftsinformatik benötigt werden
- Aufbau von Kenntnissen wichtiger mathematisch-struktureller Grundlagen der Informatik

Qualifikationsziel: Grundverständnis von technischen Informatikaspekten.

Modulziel:

- Entwicklung der Fähigkeit, die Funktionsweise elementarer Rechnerbausteine zu verstehen

Qualifikationsziel: Kenntnisse und Fertigkeiten, Problemlösungen algorithmisch zu formulieren.

Modulziel:

- Mathematisch logisches Formulieren und Schließen als Basis für Spezifikation und Umsetzung

A.10.3.2. Diskrete Mathematik 2

Positionierung im Studiengang

Dieses Modul trägt zur wissenschaftlichen Grundqualifikation der Studierenden bei. Zunächst werden mathematische Grundlagen für das Verständnis wichtiger Informatikthemen geschaffen.

Im Anschluss wird im Themengebiet Kryptografie beschrieben, wie in der modernen IT Informationen geschützt werden können. Diese Grundlagen sind unverzichtbar für einen kritischen Umgang mit den Techniken des Internets und schaffen das erforderliche Hintergrundwissen für vertrauliche Netzwerkverbindungen, wie sie zum Beispiel im Modul 'Technische Grundlagen der Informatik 2' erwartet werden.

Qualifikations_ und Modulziele

Qualifikationsziel: Befähigung zum wissenschaftlichen Arbeiten und der eigenständigen Anwendung von Methoden.

Modulziel:

- Weiterführende mathematische Begriffsbildungen, wie sie zum Verständnis wissenschaftlicher Abhandlungen der Wirtschaftsinformatik benötigt werden
- Beweisen von einfachen Aussagen
- Wissensvermittlung über Algorithmen und Mathematik von Kryptosystemen

Qualifikationsziel: Grundverständnis von technischen Informatikaspekten.

Modulziel:

- Relevanz für die Verschlüsselung

A.10.3.3. Programmierung 1

Positionierung im Studiengang

Aufgrund der hohen Bedeutung von Programmierfertigkeiten gemäß dem angestrebten Berufsbild eines Wirtschaftsinformatikers ist das Thema Softwareentwicklung im Studiengang entsprechend hoch gewichtet. Das Modul stellt den Beginn einer Kette von Modulen dar, die sich mit diesem Thema beschäftigen (fortgeführt durch die Module 'Programmierung 2', 'Praxis der Softwareentwicklung' oder 'Softwaretechnik'). In dem Modul werden Techniken vermittelt, die bei der Entwicklung von Inter- und Intranetseiten bzw. einfachen Web-Anwendungen verwendet werden.

Qualifikations_ und Modulziele

Qualifikationsziel: Kenntnisse und Fertigkeiten, Problemlösungen algorithmisch zu formulieren.

Modulziel:

- Aufbau von Kenntnissen wichtiger Grundbegriffe der Informatik, insbesondere ein Verständnis der Grundkonzepte objektorientierter Programmiersprachen

Qualifikationsziel: Kenntnis der Entwicklung und Verknüpfung von betrieblichen Informationssystemen.

Modulziel:

- Entwicklung der Fähigkeit, einfache Programme zu entwerfen, zu erstellen und zu testen, unter der Nutzung moderner Programm-Entwicklungsumgebungen
- Überblick über die im Internet typischen Anwendungsstrukturen gewinnen
- Wissen über verbreitete Internet-Standards zur Definition, zur Darstellung und zum Austausch von Dokumenten erwerben
- Fähigkeiten zur clientseitigen Informationsaufbereitung entwickeln

A.10.3.4. Programmierung 2

Positionierung im Studiengang

Aufgrund der hohen Bedeutung von Programmierfertigkeiten gemäß dem angestrebten Berufsbild eines Wirtschaftsinformatikers ist das Thema Softwareentwicklung im Studiengang entsprechend hoch gewichtet. Das Modul setzt die Kette von Modulen fort, die sich mit diesem Thema beschäftigen (fortgeführt durch die Module „Praxis der Softwareentwicklung“ oder „Softwaretechnik“). In dem Modul werden clientseitige Techniken vertieft, die bei der Entwicklung von Web-Anwendungen verwendet werden. Die Veranstaltung bildet damit auch die Grundlage für weitere Module im Bereich Softwareentwicklung, insbesondere „Betriebswirtschaftliche Anwendungen“ und „Internet Anwendungsarchitekturen“.

Qualifikations- und Modulziele

Qualifikationsziel: Kenntnisse und Fertigkeiten, Problemlösungen algorithmisch zu formulieren.

Modulziel:

- Vertiefung von Kenntnissen der Grundkonzepte der objektorientierten Programmierung

Qualifikationsziel: Kenntnis der Entwicklung und Verknüpfung von betrieblichen Informationssystemen.

Modulziel:

- Entwicklung der Fähigkeit, einfache Programme zu entwerfen, zu erstellen und zu testen, unter der Nutzung moderner Programm-Entwicklungsumgebungen
- Kenntnisse und Fertigkeiten in der Nutzung von Web-Frameworks vertiefen
- Grundprinzipien der Informationsdarstellung für Menschen und Computer kennen und beherrschen
- Technische Entwicklungen im Spannungsumfeld von Standards/Normen und praktischen Zwängen einordnen und einschätzen können
- Aufbau von praktischen Fertigkeiten zur Gestaltung von Webseiten für betriebliche Anforderungen

A.10.4. B.Sc. Angewandte Informatik

Nachfolgend finden sich die aus dem Modulhandbuch zum Studiengang ab 2014 unverändert entnommenen Modulbeschreibungen der drei für diese Arbeit relevanten Module. Herausgegeben werden die Module intern an alle Studierenden der Nordakademie (Behringer 2016)

A.10.4.1. Diskrete Mathematik 1

Positionierung im Studiengang

Das Modul ist Voraussetzung für eine wissenschaftliche Auseinandersetzung mit Informatikthemen. Es vermittelt die formalen Ausdrucksmittel, die in einem wissenschaftlichen Studiengang benötigt werden, und die grundlegenden methodischen Fähigkeiten des deduktiven Schließens. Es werden die Grundlagen des Arbeitens mit Booleschen Ausdrücken, wie sie in jeder Programmiersprache benötigt werden, vermittelt. Hierfür wird begleitend zur Vorlesung ein fakultatives Seminar mit Laborübungen angeboten.

Qualifikations- und Modulziele

Qualifikationsziel: Befähigung zum wissenschaftlichen Arbeiten und der eigenständigen Anwendung von Methoden.

Modulziel:

- Grundlagen mathematischer Begriffsbildungen, wie sie zum Verständnis wissenschaftlicher Abhandlungen der Wirtschaftsinformatik benötigt werden
- Aufbau von Kenntnissen wichtiger mathematisch-struktureller Grundlagen der Informatik

Qualifikationsziel: Grundverständnis von technischen Informatikaspekten.

Modulziel:

- Entwicklung der Fähigkeit, die Funktionsweise elementarer Rechnerbausteine zu verstehen

Qualifikationsziel: Kenntnisse und Fertigkeiten, Problemlösungen algorithmisch zu formulieren.

Modulziel:

- Mathematisch logisches Formulieren und Schließen als Basis für Spezifikation und Umsetzung

A.10.4.2. Diskrete Mathematik 2

Positionierung im Studiengang

Dieses Modul trägt zur wissenschaftlichen Grundqualifikation der Studierenden bei. Zunächst werden mathematische Grundlagen für das Verständnis wichtiger Informatikthemen geschaffen. Im Anschluss wird im Themengebiet Kryptografie beschrieben, wie in der modernen IT Informationen geschützt werden können. Diese Grundlagen sind unverzichtbar für einen kritischen Umgang mit den Techniken des Internets und schaffen das erforderliche Hintergrundwissen für vertrauliche Netzwerkverbindungen, wie sie zum Beispiel im Modul 'Technische Grundlagen der Informatik 2' erwartet werden.

Qualifikations- und Modulziele

Qualifikationsziel: Befähigung zum wissenschaftlichen Arbeiten und der eigenständigen Anwendung von Methoden.

Modulziel:

- Weiterführende mathematische Begriffsbildungen, wie sie zum Verständnis wissenschaftlicher Abhandlungen der Wirtschaftsinformatik benötigt werden
- Beweisen von einfachen Aussagen
- Wissensvermittlung über Algorithmen und Mathematik von Kryptosystemen

Qualifikationsziel: Grundverständnis von technischen Informatikaspekten.

Modulziel:

- Relevanz für die Verschlüsselung

A.10.4.3. Programmierung 1

Positionierung im Studiengang

Aufgrund der hohen Bedeutung von Programmierfertigkeiten in Berufsbildern der Informatik ist das Thema Softwareentwicklung im Studiengang entsprechend hoch gewichtet. Das Modul stellt den Beginn einer Kette von Modulen dar, die sich mit diesem Thema beschäftigen (fortgeführt durch die Module 'Programmierung 2', 'Praxis der Softwareentwicklung' und weitere). In dem Modul werden Techniken vermittelt, die bei der Entwicklung von Inter- und Intranetseiten bzw. einfachen Web-Anwendungen verwendet werden.

Qualifikations- und Modulziele

Qualifikationsziel: Kenntnisse und Fertigkeiten zur algorithmischen Formulierung von Problemlösungen und ihrer Umsetzung in verständliche und effiziente Computerprogramme.

Modulziel:

- Aufbau von Kenntnissen wichtiger Grundbegriffe der Informatik, insbesondere ein Verständnis der Grundkonzepte objektorientierter Programmiersprachen
- Erste Erfahrungen in der Nutzung von Web-Frameworks sammeln

Qualifikationsziel: Befähigung zum Einsatz professioneller Methoden und Werkzeuge zur Softwareentwicklung.

Modulziel:

- Aufbau grundlegender Fertigkeiten im Umgang mit professionellen Entwicklungsumgebungen

Qualifikationsziel: Fähigkeit, Mensch-Computer-Interaktionen zu modellieren und umzusetzen

Modulziel:

- Aufbau grundlegender Kenntnisse und Fertigkeiten der Gestaltung und Realisierung einfacher interaktiver Benutzungsoberflächen für Web-Anwendungen

Positionierung im Studiengang

Aufgrund der hohen Bedeutung von Programmierfertigkeiten gemäß dem angestrebten Berufs-

Das Profil eines Angewandten Informatikers ist das Thema Softwareentwicklung im Studiengang entsprechend hoch gewichtet. Das Modul setzt die Kette von Modulen fort, die sich mit diesem Thema beschäftigen (fortgeführt durch die Module „Praxis der Softwareentwicklung“ oder „Softwaretechnik“). In dem Modul werden clientseitige Techniken vertieft, die bei der Entwicklung von Web-Anwendungen verwendet werden. Die Veranstaltung bildet damit auch die Grundlage für weitere Module im Bereich Softwareentwicklung, insbesondere „Betriebswirtschaftliche Anwendungen“ und „Internet Anwendungsarchitekturen“.

Qualifikations- und Modulziele

Qualifikationsziel: Kenntnisse und Fertigkeiten zur algorithmischen Formulierung von Problemlösungen und ihrer Umsetzung in verständliche und effiziente Computerprogramme.

Modulziel: Vertiefung von Kenntnissen der Grundkonzepte der objektorientierten

A.10.4.4. Programmierung 2

Positionierung im Studiengang

Aufgrund der hohen Bedeutung von Programmierfertigkeiten in Berufsfeldern der Informatik ist das Thema Softwareentwicklung im Studiengang entsprechend hoch gewichtet. Das Modul setzt die Kette von Modulen fort, die sich mit diesem Thema beschäftigen. In dem Modul werden clientseitige Techniken vertieft, die bei der Entwicklung von Web-Anwendungen verwendet werden. Die Veranstaltung bildet damit auch die Grundlage für weitere Module im Bereich Softwareentwicklung, wie z.B. „Internet Anwendungsarchitekturen“.

Qualifikations- und Modulziele

Qualifikationsziel: Kenntnisse und Fertigkeiten zur algorithmischen Formulierung von Problemlösungen und ihrer Umsetzung in verständliche und effiziente Computerprogramme

Modulziel: Vertiefung von Kenntnissen der Grundkonzepte der objektorientierten Programmierung

Qualifikationsziel: Befähigung zum Einsatz professioneller Methoden und Werkzeuge zur Softwareentwicklung.

Modulziel: Absolventen können einfache, interaktive Benutzungsoberflächen für Web-Anwendungen entwerfen und unter Einsatz adäquater Web-Technologien implementieren.

B. Anlagen

Auf der DVD in der Anlage werden folgende Inhalte bereitgestellt:

- Persistierte Online-Quellen
- Interne Dokumente (u.a. das Exposé)
- Untersuchungsdaten
- R-Skripte zur Untersuchung
- Experteninterview-Transkripte
- Readme-Datei zum Inhalt der DVD
- Abbildungen
- Masterthesis als PDF-Dokument

Eidesstattliche Erklärung

Hiermit versichere ich, dass ich die vorliegende akademische Abschlussarbeit selbstständig und ohne fremde Hilfe angefertigt habe.

Alle Textstellen, die ich wörtlich oder sinngemäß aus veröffentlichten oder nicht veröffentlichten Quellen übernommen habe, wurden von mir als solche gekennzeichnet.

Hamburg, den 14. März 2017

Dirk Johannßen