

Optimierung der Personaleinsatzplanung
in Call Centern

Theoretische Systematisierung und empirische Überprüfung

Inaugural-Dissertation zur Erlangung des
akademischen Grades eines Doktors
der Wirtschaftswissenschaften
im Fachbereich Statistik
der Universität Passau

vorgelegt von
KATHRIN HUBER
Passau
August 2006

Inhaltsverzeichnis

| | |
|------------------------------------|--|
| Abbildungsverzeichnis | VI |
| Tabellenverzeichnis..... | IX |
| Diagrammverzeichnis | X |
| Symbolverzeichnis..... | XII |
| Abkürzungsverzeichnis..... | XVI |
| | |
| 1 | Einleitung..... 1 |
| 1.1 | Motivation und Problemstellung..... 1 |
| 1.2 | Gang der Arbeit..... 4 |
| | |
| 2 | Call Centers 7 |
| 2.1 | Arten von Call Centern 7 |
| 2.2 | Technische Ausstattung in Call Centern..... 9 |
| 2.3 | Statistische Kennzahlen und Einflussparameter im Call Center 12 |
| 2.3.1 | Generierte Daten aus der ACD-Anlage 12 |
| 2.3.2 | Die Erreichbarkeit 15 |
| 2.3.3 | Der Servicelevel 16 |
| 2.3.4 | Die Wartetoleranz der Anrufer 17 |
| 2.3.5 | Subjektive versus objektive Wartezeit..... 18 |
| 2.3.6 | Der Einfluss des Servicelevels auf die Kosten im Call Center 19 |
| 2.3.7 | Die Mitarbeiterauslastung 23 |
| 2.4 | Die Mitarbeiterstruktur in Call Centern 24 |
| 2.5 | Die Wahl der richtigen Rufnummer..... 27 |
| | |
| 3 | Grundlagen künstlicher neuronaler Netze 29 |
| 3.1 | Das biologische Vorbild..... 29 |

| | | |
|-----------|--|-----------|
| 3.2 | Ein einfaches Modell künstlicher neuronaler Netze | 31 |
| 3.2.1 | Das Neuron als kleinste Einheit im System | 31 |
| 3.2.2 | Verbindungen und Netzwerktopologie | 33 |
| 3.3 | Funktionale Zusammenhänge | 35 |
| 3.3.1 | Die Propagierungsfunktion | 35 |
| 3.3.2 | Die Aktivierungsfunktion | 37 |
| 3.3.3 | Die Outputfunktion | 42 |
| 3.4 | Lernen im künstlichen neuronalen Netz | 44 |
| 3.4.1 | Lernaufgaben | 45 |
| 3.4.2 | Lernkonzepte..... | 47 |
| 3.4.3 | Grundlegende Lernregeln | 49 |
| 3.4.3.1 | Unüberwachtes Lernen: Hebbsche Lernregel | 49 |
| 3.4.3.2 | Überwachtes Lernen: Delta-Regel | 52 |
| 3.4.3.3 | Überwachtes Lernen: Generalisierte Delta-Regel oder Backpropagation-Algorithmus..... | 53 |
| 3.4.3.3.1 | Grundlagen..... | 53 |
| 3.4.3.3.2 | Herleitung des Backpropagation-Algorithmus | 56 |
| 3.4.3.3.3 | Formale Berechnung der Gewichtsanzpassung in einem dreistufigen Netzwerk mit einer verdeckten Schicht | 65 |
| 3.4.3.4 | Wahl des richtigen Abbruchkriteriums | 72 |
| 3.5 | Kritische Würdigung des Backpropagation-Algorithmus..... | 75 |
| 3.5.1 | Lokale Minima..... | 75 |
| 3.5.2 | Oszillation in steilen Schluchten..... | 77 |
| 3.5.3 | Flache Plateaus..... | 78 |
| 3.5.4 | Richtige Wahl des Lernfaktors | 79 |
| 4 | Prognose des Callvolumens im Call Center zur strategischen Personaleinsatzplanung | 81 |
| 4.1 | Beschreibung der Rahmenbedingungen zur Prognose..... | 81 |
| 4.2 | Identifikation der Einflussparameter..... | 82 |
| 4.3 | Überprüfung der Daten | 88 |
| 4.4 | Modellspezifikation | 101 |
| 4.4.1 | Optimierung der Netzwerktopologie | 101 |
| 4.4.2 | Optimierung der Netzwerkparameter..... | 106 |

| | | |
|----------|---|------------|
| 4.5 | Modellschätzung und Überprüfung | 110 |
| 4.6 | Zusammenfassung der empirischen Analyse..... | 124 |
| 5 | Die Warteschlangentheorie als Grundlage der Personaleinsatzplanung..... | 125 |
| 5.1 | Bedeutung der Warteschlangen- und Bedientheorie für Call Centers – Der Warteschlangenprozess | 125 |
| 5.2 | Eigenschaften und Kenngrößen von Warteschlangenmodellen | 128 |
| 5.2.1 | Der Ankunftsprozess..... | 129 |
| 5.2.2 | Die Servicezeit | 131 |
| 5.2.3 | Die Bedeutung der Exponentialverteilung..... | 132 |
| 5.2.4 | Der Geburts- und Sterbeprozess | 140 |
| 5.3 | Die Kendall-Symbolik | 149 |
| 5.4 | Das Erlang Modell als Grundlage der traditionellen Ermittlung des Personalbedarfs | 152 |
| 5.4.1 | Das Annahmensystem..... | 152 |
| 5.4.2 | Herleitung des Erlang C-Modells | 155 |
| 5.4.3 | Kritische Würdigung | 164 |
| 6 | Modifikation und Erweiterung des Erlang C- Modells – Eine Simulationsstudie..... | 167 |
| 6.1 | Analyse der Ankunftszeiten | 167 |
| 6.1.1 | Überprüfung homogener Poisson-Prozesse | 168 |
| 6.1.2 | Test auf stochastische Unabhängigkeit..... | 171 |
| 6.1.3 | Überprüfung der Verteilungsannahme..... | 174 |
| 6.2 | Analyse der Servicezeiten..... | 177 |
| 6.2.1 | Test auf stationäre Servicezeiten..... | 178 |
| 6.2.2 | Überprüfung der stochastischen Unabhängigkeit | 184 |
| 6.2.3 | Überprüfung der Verteilungsannahme..... | 186 |
| 6.3 | Konsequenzen aus der Analyse der Interarrival- und Servicezeiten | 189 |
| 6.4 | Simulation der Personaleinsatzplanung unter einem realistischen Annahmensystem..... | 190 |

| | | |
|---------------|--|------------|
| 6.4.1 | Einstellungsparameter und wichtige Kenngrößen als Referenzmaße..... | 190 |
| 6.4.2 | Ergebnisse der Simulation und Bedeutung für die operative Personaleinsatzplanung | 192 |
| 6.4.3 | Vergleich des Schichtmodells aus der Simulationsstudie mit dem aus der traditionellen Personaleinsatzplanung..... | 201 |
| 7 | Zusammenfassung..... | 205 |
| Anhang | | 208 |
| A1 | Überprüfung der Einflussparameter zur Callprognose | 209 |
| A1.1 | Varianzanalyse für den Jahresvergleich des Callaufkommens | 209 |
| A1.2 | Varianzanalyse für den Monatsvergleich..... | 210 |
| A1.3 | Paarvergleich der Monate August und September..... | 211 |
| A1.4 | Paarvergleich der Monate August und Oktober..... | 211 |
| A1.5 | Varianzanalyse für den Tagesvergleich | 212 |
| A1.6 | Paarweiser Vergleich der Tagesperformances | 213 |
| A1.7 | Vergleich Wochenende/Feiertag und Werktag | 216 |
| A1.8 | Analyse des Interaktionseffekts (Intercept) von Feiertag und Wochentag | 217 |
| A1.9 | Sukzessiver Paarvergleich zur Identifikation jener Interaktionseffekte, die zur Ablehnung der Varianzanalyse führten | 218 |
| A1.10 | Mittelwertvergleich unter Ausschluss von „normalen“ Werktagen (kein Feiertag) | 220 |
| A1.11 | Korrelation von Uhrzeit und Calls | 221 |
| A1.12 | Untersuchung des Einflusses von Marketingmaßnahmen | 222 |
| A2 | Netzwerkoptimierung..... | 223 |
| A2.1 | Untersuchung der Struktur des Hidden Layers | 223 |
| A2.2 | Verbesserung der Netzwerkperformance durch Optimierung der Codierung der Einflussvariablen „Feiertag/Wochenende“ | 228 |
| A3 | Überprüfung der Prämissen des Erlang C-Modells | 229 |

| | | |
|----------------------------------|---|------------|
| A3.1 | Analyse der Ankunftszeiten | 229 |
| A3.2 | Analyse der Servicezeiten | 231 |
| A3.2.1 | Mittelwertvergleich der Gesprächszeiten bei Unterscheidung zwischen Tages- und Nachtstunden..... | 231 |
| A3.2.2 | Analyse stationärer Servicezeiten innerhalb der Stundenintervalle | 234 |
| A4 | Simulationsstudie | 242 |
| A4.1 | Übersicht der Simulationsergebnisse | 242 |
| A4.2 | Idle-Time sonntags..... | 244 |
| A4.3 | Vergleich des Callaufkommens an Feiertagen mit dem an Wochenenden..... | 249 |
| A5 | Quellcode der Simulationsstudie | 253 |
| A5.1 | Simulation für Montag | 253 |
| A5.2 | Simulation für Dienstag bis Freitag | 254 |
| A5.3 | Simulation für Samstag..... | 257 |
| A5.4 | Simulation für Sonntag | 259 |
| Literaturverzeichnis..... | | 263 |

Abbildungsverzeichnis

| | | |
|-----------------|---|----|
| Abbildung 2.1: | Kategorisierung von Call Centern | 8 |
| Abbildung 2.2: | Technische Komponenten eines Call Centers | 10 |
| Abbildung 2.3: | Bearbeitungs- und Eingabemaske für die Rohdaten aus der ACD-Anlage | 13 |
| Abbildung 2.4: | Darstellung der zu unterscheidenden Gesprächszeiten | 14 |
| Abbildung 2.5: | Verlauf der subjektiven und objektiven Wartezeit | 19 |
| Abbildung 2.6: | Qualifikationsprofil von Agenten | 26 |
| Abbildung 3.1: | Formaler Aufbau eines Neurons | 32 |
| Abbildung 3.2: | Überblick über die möglichen Aktivierungszustände | 38 |
| Abbildung 3.3: | Überblick über die grundlegenden Aktivierungsfunktionen | 39 |
| Abbildung 3.4: | Logistische Funktion | 41 |
| Abbildung 3.5: | Tangens Hyperbolicus Funktion | 42 |
| Abbildung 3.6: | Zusammenfassung der funktionalen Zusammenhänge in einem Neuron | 43 |
| Abbildung 3.7: | Assoziatives Lernen | 46 |
| Abbildung 3.8: | Übersicht über die verschiedenen Lernregeln | 49 |
| Abbildung 3.9: | Schematischer Aufbau eines MLP mit einem Hidden Layer | 54 |
| Abbildung 3.10: | Fehlergebirge im zweidimensionalen Raum | 57 |
| Abbildung 3.11: | Prinzip des Gradientenabstiegsverfahrens | 58 |
| Abbildung 3.12: | MLP mit einem Hidden Layer | 66 |
| Abbildung 3.13: | Optimaler Zeitpunkt des Trainingsabbruches | 74 |
| Abbildung 3.14: | Lokales Minimum auf der Fehleroberfläche | 76 |
| Abbildung 3.15: | Oszillation in steilen Schluchten | 77 |
| Abbildung 3.16: | Flache Plateaus | 79 |
| Abbildung 3.17: | Überspringen des globalen Minimums bei zu großer Wahl der Lernrate | 80 |
| Abbildung 4.1: | Ergebnis der Varianzanalyse für den Jahresvergleich | 89 |
| Abbildung 4.2: | Ergebnis der Varianzanalyse für den Monatsvergleich | 90 |
| Abbildung 4.3: | Ergebnis der Varianzanalyse für den Tagesvergleich | 91 |

| | | |
|-----------------|---|-----|
| Abbildung 4.4: | Ergebnis des Vergleichs von Calls an Werktagen und Feiertagen/Wochenenden | 93 |
| Abbildung 4.5: | Korrelation zwischen Anruf und Uhrzeit (vormittags)..... | 95 |
| Abbildung 4.6: | Korrelation zwischen Anruf und Uhrzeit (nachmittags/abends) | 96 |
| Abbildung 4.7: | Ergebnis der Analyse von Marketingmaßnahmen..... | 99 |
| Abbildung 4.8: | Untersuchung von Marketingmaßnahmen bei verkürztem Betrachtungsintervall..... | 100 |
| Abbildung 4.9: | MLP-Topologie für das vorliegende Prognoseproblem | 102 |
| Abbildung 4.10: | Verfall der Lernrate während der Trainingsphase..... | 107 |
| Abbildung 4.11: | Netztopologie bei der Prognose der Tagesperformance | 111 |
| Abbildung 5.1: | Anrufprozess in einem Call Center | 126 |
| Abbildung 5.2: | Differenzierung der unterschiedlichen Gesprächszeiten | 127 |
| Abbildung 5.3: | Schematische Modellierung des Wartesystems in einem Call Center | 128 |
| Abbildung 5.4: | Aufteilung eines Zeitintervalls t in m Einzelintervalle..... | 137 |
| Abbildung 5.5: | Übergangsgraph zur Darstellung des Geburts- und Sterbeprozesses..... | 142 |
| Abbildung 5.6: | Übergangsgraph für das Erlang C-Modell..... | 154 |
| Abbildung 6.1: | Simulationsergebnis montags | 193 |
| Abbildung 6.2: | Schichtmodell montags | 194 |
| Abbildung 6.3: | Schichtmodell Dienstag bis Freitag | 195 |
| Abbildung 6.4: | Schichtmodell samstags..... | 196 |
| Abbildung 6.5: | Schichtmodell sonntags | 196 |
| Abbildung 6.6: | Schichtmodell mit Pausen (montags) | 197 |
| Abbildung 6.7: | Vergleich des Schichtmodells mit Pausen mit dem Simulationsergebnis (montags) | 198 |
| Abbildung 6.8: | Vergleich des Schichtmodells mit Pausen mit dem Simulationsergebnis (Dienstag bis Freitag)..... | 199 |
| Abbildung 6.9: | Vergleich des Schichtmodells mit Pausen mit dem Simulationsergebnis (Samstag) | 199 |

| | |
|---|-----|
| Abbildung 6.10: Vergleich des Schichtmodells mit Pausen mit dem Simulationsergebnis (Sonntag)..... | 200 |
| Abbildung 6.11: Vergleich des neu simulierten Modells mit dem traditionellen (Montag)..... | 201 |
| Abbildung 6.12: Vergleich des neu simulierten Modells mit dem traditionellen (Dienstag bis Freitag)..... | 202 |
| Abbildung 6.13: Vergleich des neu simulierten Modells mit dem traditionellen (Samstag)..... | 202 |
| Abbildung 6.14: Vergleich des neu simulierten Modells mit dem traditionellen (Sonntag)..... | 203 |

Tabellenverzeichnis

| | |
|---|-----|
| Tabelle 2.1: Übersicht über die wichtigsten statistischen Daten aus der ACD-Anlage | 14 |
| Tabelle 2.2: Zusammenhang zwischen Servicelevel und Auslastung | 23 |
| Tabelle 5.1: Bedeutung der Abkürzungen in der Kendall-Symbolik..... | 49 |
| Tabelle 6.1: χ^2 -Test | 170 |
| Tabelle 6.2: Korrelation zwischen $\{T_i\}$ und $\{T_{i-1}\}$ (Tagesbasis)..... | 172 |
| Tabelle 6.3: Korrelation zwischen $\{T_i\}$ und $\{T_{i-1}\}$ (10:00 bis 12:00 Uhr) | 173 |
| Tabelle 6.4: Korrelation zwischen $\{T_i\}$ und $\{T_{i-1}\}$ (8:00 bis 12:00 Uhr)..... | 173 |
| Tabelle 6.5: Übersicht der Ergebnisse der Verteilungsanpassung der Interarrivalzeiten | 177 |
| Tabelle 6.6: Analyse der Gesprächszeiten an Werktagen | 183 |
| Tabelle 6.7: Analyse der Gesprächszeitreihe am Wochenende | 183 |
| Tabelle 6.8: Korrelationsanalyse der Gesprächszeiten | 185 |
| Tabelle 6.9: Übersicht der optimalen Servicezeit-Verteilung..... | 188 |

Diagrammverzeichnis

| | | |
|----------------|---|-----|
| Diagramm 1.1: | Kostenstruktur in Call Centern | 2 |
| Diagramm 2.1: | Zusammenhang zwischen Servicelevel und Anzahl der benötigten Operatoren | 20 |
| Diagramm 2.2: | Zusammenhang zwischen Wartezeit und Servicewahrscheinlichkeit | 21 |
| Diagramm 2.3: | Zunahme des Servicelevels bei Einsatz zusätzlicher Agenten..... | 22 |
| Diagramm 4.1: | Jahresübersicht über die Monatsmittelwerte (Calls absolut) | 83 |
| Diagramm 4.2: | Wochenüberblick..... | 84 |
| Diagramm 4.3: | Tagesübersicht (gemittelte Stundenwerte des Monats September 2004)..... | 85 |
| Diagramm 4.4: | Darstellung der Einflussgrößen „Wochentag“ und „Uhrzeit“..... | 87 |
| Diagramm 4.5: | Jahresvergleich im Callaufkommen | 88 |
| Diagramm 4.6: | Paarweiser Vergleich der Tagesperformance | 92 |
| Diagramm 4.7: | Ergebnisse des Signifikanztests zum Interaktionseffekt von Feiertagen und Wochentag..... | 94 |
| Diagramm 4.8: | Anrufzahlen unter Beachtung von Marketingmaßnahmen | 98 |
| Diagramm 4.9: | Vergleich des Netzwerkfehlers bei 15 Hidden Layers mit dem bei 10, 11, 12 und 13 verdeckten Schichten..... | 104 |
| Diagramm 4.10: | Vergleich des Netzwerkfehlers bei 15 Hidden Layers mit dem bei 14, 16, und 17 verdeckten Schichten..... | 105 |
| Diagramm 4.11: | Vergleich des Netzwerkfehlers bei 15 Hidden Layers mit dem bei 18, 19 und 20 verdeckten Schichten..... | 105 |
| Diagramm 4.12: | Mittlerer Netzfehler bei unterschiedlicher Codierung der Variablen „FE“ | 109 |
| Diagramm 4.13: | Überblick über den vollständig prognostizierten Datensatz | 112 |
| Diagramm 4.14: | Scatterplot der Ergebnisse für die Tagesprognose | 116 |

| | | |
|----------------|--|-----|
| Diagramm 4.15: | Scatterplot mit Unterscheidung von Feiertagen und normalen Wochentagen | 117 |
| Diagramm 4.16: | Scatterplot mit Differenzierung der Daten nach Monat und Feiertagen | 118 |
| Diagramm 4.17: | Einzelvergleich der Callperformance zur Weihnachtszeit mit normalem Callvergleich | 119 |
| Diagramm 4.18: | Vergleich der Ergebnisse der 15 Min-Prognosen..... | 121 |
| Diagramm 4.19: | Scatterplot der Viertelstunde-Prognose | 122 |
| Diagramm 4.20: | Scatterplot über die Weihnachtsphase | 123 |
| Diagramm 6.1: | Gleichverteilungsplot der kumulierten relativen Häufigkeiten | 169 |
| Diagramm 6.2: | Streudiagramm zur Überprüfung der Unabhängigkeit der Interarrivalzeiten..... | 171 |
| Diagramm 6.3: | Verteilungsanpassung der Interarrivalzeiten durch die Exponentialverteilung..... | 175 |
| Diagramm 6.4: | Verteilungsanpassung der Interarrivalzeiten durch die Gammaverteilung | 176 |
| Diagramm 6.5: | Varianzen der Servicezeiten im Tagesablauf | 178 |
| Diagramm 6.6: | Anteil kleiner Servicezeiten an der Gesamthäufigkeit | 179 |
| Diagramm 6.7: | Verlauf der mittleren Servicezeit im Tagesablauf (Werktag/Wochenende)..... | 181 |
| Diagramm 6.8: | t-Test zur Überprüfung der Konkordanz der Servicezeiten an Werktagen und Wochenenden | 182 |
| Diagramm 6.9: | Streudiagramm der Gesprächszeiten | 185 |
| Diagramm 6.10: | Verteilungsanpassung der Gesprächszeiten durch die Exponentialverteilung..... | 187 |
| Diagramm 6.11: | Verteilungsanpassung der Gesprächszeiten durch die Lognormalverteilung | 188 |
| Diagramm 6.12: | Durchschnittliche Idle-Time sonntags..... | 204 |

Symbolverzeichnis

Kapitel: Neuronale Netze

| | |
|-------------------|--|
| $f'_{act}(\cdot)$ | 1. Ableitung der Aktivierungsfunktion |
| $f_{act}(\cdot)$ | Aktivierungsfunktion |
| a_j | Aktivierungsgrad von Neuron j |
| v_t | Anzahl der Call im Viertelstundenintervall zum Zeitpunkt t |
| δ_j | Differenz zwischen aktueller Aktivierung a_j und erwarteter t_j |
| E_p | Fehlerfunktion für das Eingabemuster p |
| W | Gewichtungsmatrix |
| ∇ | Gradientenoperator |
| η_{high} | höchste Lernrate |
| $f_{in}(\cdot)$ | Inputfunktion |
| o_{pj} | Istausgabewert des Ausgabeneurons j für Trainingsmuster p |
| n_j | j -tes Neuron im Netzwerk |
| η | Lernrate |
| μ | Momentum-Term |
| $net_j^{(k)}$ | Nettoinput des Neurons j in Schicht $(k+1)$, das aus Schicht (k) resultiert |
| net_j | Nettoinput von Neuron j |
| x_i | Netzeingang für Neuron j von Neuron i |
| η_{low} | niedrigste Lernrate |
| $o_j^{(k)}$ | Output des Neurons j in Schicht (k) |
| o_j | Output von Neuron j |
| $f_{out}(\cdot)$ | Outputfunktion |
| e_i | Prognosefehler |
| \hat{y}_i | prognostizierte Anzahl an Calls |

| | |
|--------------------------------|---|
| t_{pj} | Sollausgabewert des Ausgabeneurons j für Trainingsmuster p |
| y_i | tatsächliche Anzahl an Calls |
| t_j | Teaching Unit für das j -te Neuron; erwartete Aktivierung |
| ∞ | unendlich |
| u_j | Unit j |
| $w_{ij}^{(k)}$ | Verbindungsgewicht am Übergang von Neuron i in Schicht (k) zu Neuron j in Schicht ($k+1$) |
| w_{ij} | Verbindungsgewicht von Neuron i zu Neuron j |
| w_{jk} | Verbindungsgewicht zwischen Neuron j und dem Neuron k der nächst höheren Schicht |
| $W^{(i)}$ | Verbindungsgewichte in Schicht i |
| $f(\cdot), g(\cdot), h(\cdot)$ | allgemeine Funktionen |
| $\tanh(\cdot)$ | Tangens Hyperbolicus Funktion |
| $f_{trans}(\cdot)$ | Transferfunktion |
| d | Verfall der Lernrate |
| E | Gesamtfehler |
| k | Anzahl der Stufen in einem Netzwerk |
| l | Anzahl der Schichten in einem Netzwerk |
| MAE | Mittlerer absoluter Prognosefehler |
| MAPE | Mittlerer absoluter prozentualer Prognosefehler |
| ME | Mittlerer Prognosefehler |
| MPE | Mittlerer prozentualer Prognosefehler |
| MSE | Mittlerer quadrierter Prognosefehler |
| N | Gesamtanzahl an Neuronen im Netzwerk |
| p | Trainingsmuster (pattern) |
| r | Korrelationskoeffizient nach Bravais-Pearson |
| RMSE | Quadratwurzel aus dem mittleren quadrierten Prognosefehler |
| t | Zeitpunkt |
| U | Theil'sches Fehlermaß |

Kapitel: Warteschlangenmodelle

| | |
|----------------|--|
| n_i | <i>absolute Häufigkeit für das Vorkommen der Anzahl an Calls</i> |
| | z_i |
| λ | <i>Ankunftsrate der Calls</i> |
| z_i | <i>Anzahl der Calls pro Ankunftsintervall</i> |
| ρ | <i>Auslastungsgrad</i> |
| E_k | <i>Erlang verteilte Ankunfts- bzw. Servicezeitrate</i> |
| L_s | <i>erwartete Anzahl an Anrufern, die sich im System befinden</i> |
| L_q | <i>erwartete Anzahl an Anrufern, die sich in der Warteschlange befinden</i> |
| $\{T_i\}$ | <i>i-te Zeit zwischen zwei Anrufen</i> |
| x_t | <i>konkrete Ausprägung des Zustands eines stochastischen Systems</i> |
| β | <i>Lageparameter der Gammaverteilung</i> |
| \bar{t}_{ar} | <i>Mittlere Interarrivaltime</i> |
| \bar{t}_{st} | <i>Mittlere Servicezeit</i> |
| μ | <i>Servicezeitrate</i> |
| t_{ab} | <i>Servicezeit allgemein</i> |
| t_{abj} | <i>Servicezeit eines Agenten mit der Dauer j</i> |
| $\{X_i\}$ | <i>Stochastischer Prozess</i> |
| α | <i>Verteilungsparameter der Exponentialverteilung/ Formparameter der Gammaverteilung</i> |
| P_n | <i>Wahrscheinlichkeit für Zustand n</i> |
| W_s | <i>Wartezeit im Gesamtsystem</i> |
| W_q | <i>Wartezeit in der Warteschlange</i> |
| T_q | <i>Zufallsvariable für die Wartezeit in der Warteschlange</i> |
| $X_t / X(t)$ | <i>Zustand eines stochastischen Systems zum Zeitpunkt t</i> |
| a | <i>Arbeitslast</i> |
| c | <i>Anzahl an Agenten im System</i> |

| | |
|-------------|---|
| <i>D</i> | <i>deterministisch verteilte Ankunfts- bzw. Servicezeitrate</i> |
| <i>GT/G</i> | <i>Beliebig verteilte Ankunfts- bzw. Servicezeitrate</i> |
| <i>m</i> | <i>Anzahl der Intervalle in die eine bestimmte Zeitspanne t unterteilt werden kann</i> |
| <i>M</i> | <i>Exponentialverteilte Ankunfts- bzw. Servicezeitrate</i> |
| <i>n</i> | <i>Anzahl der Calls im Datensatz</i> |
| <i>T</i> | <i>Zufallsvariable</i> |

Abkürzungsverzeichnis

| | |
|--------|---|
| Abs. | Absatz |
| ACD | Automatic Call Distributor |
| Art. | Artikel |
| ASA | durchschnittliche Zeitdauer bis ein Anruf angenommen wird |
| AV | Ausgabevektor |
| bzw. | Beziehungsweise |
| CSG | Call Statistics Generator |
| CTI | Computer Telephony Integration |
| d. h. | das heißt |
| ECD | Elapsed Conversation Duration |
| et al. | et alter |
| EV | Eingabevektor |
| f. | folgende |
| FCFS | First Come First Served |
| FE | Feiertag/Wochenende |
| FIFO | First In First Out |
| HL | Hidden Layer |
| HN | Hidden Neuron |
| IN | Input Neuron |
| IVR | Interactive Vice Response |
| KNN | künstliches neuronales Netz |
| LAN | Local Area Network |
| LCFS | Last Come First Served |
| LIFO | Last In First Out |
| max | maximal |
| min | minimal |
| Min. | Minute |
| MLP | Multi-Layer-Perceptrone |
| MW-FE | Mittelwert der Calls an Wochenenden und Feiertagen |
| MW-WT | Mittelwert der Calls an Werktagen |
| OCD | Operator Conversation Duration |

| | |
|------------|---|
| OID | Operator Intervention Duration |
| ON | Output Neuron |
| PIN | Personal Identification Number |
| Q1, Q2, Q3 | Qualifikationslevel von Agenten |
| s. | Seite |
| Sek. | Sekunde |
| SIRO | Service in Random Order |
| SLA% | Servicelevel |
| Sog. | so genannte |
| SZ | Servicezeit |
| T(ab) | Gesprächszeit im System |
| TDSV | Telekommunikationsdienstunternehmen-Datenschutzverordnung |
| TK | Telekommunikationsanlage |
| u. a. | unter anderem |
| Vgl. | Vergleiche |
| WT | Werktag |

Kapitel 1: Einleitung

1.1 Motivation und Problemstellung

Eine Branche, die in den letzten Jahren einer rasanten Entwicklung unterworfen war, ist die des *Call Center-Marktes*.

Gründe hierfür liegen unter anderem in der Erkenntnis vieler Unternehmen, dass kommunikative Komponenten entscheidend sind für die Kundenzufriedenheit und Kundenbindung. Dazu gehört nicht nur eine Anlaufstelle für Beschwerden oder Kundenanfragen in Form von Help Desk Funktionen, sondern auch weiterführende Kundenbetreuungsmaßnahmen mittels Telefonhotlines. Viele Unternehmen versuchen diesen Aspekt auszulagern und beauftragen externe Call Center, diese Dienstleistung für sie zu erbringen.

Auf der anderen Seite hat aber auch gerade die Liberalisierung und Öffnung des Telekommunikationsmarktes dazu geführt, dass mehr und mehr Anbieter für Telefonauskunft das Wachstumspotential dieses Marktes erkannt haben und ihre Dienste anbieten.

Als Konsequenz daraus ergab sich gemäß der Benchmark-Studie von 2001 extrem große Wachstumsraten.¹ Das Callvolumen ist geradezu explosionsartig nach oben geschneit, was auch andeutet, in welchem Umfang dieses Dienstleistungsangebot von den Kunden angenommen wird.

Vergleicht man die wesentlichen Aussagen der Benchmark-Studie von 2001 allerdings mit denen aus 2003, so hat sich das Bild etwas gewandelt, zumal eine Stagnation in diesem Sektor zu verzeichnen war. Die Schlagwörter sind nun „*Kostendruck*“ und „*wirtschaftlicher Stillstand*“, wobei diesen noch zusätzlich „*hohe Serviceerwartungen*“ von Seiten der Kunden gegenüberstehen.² Der Qualitätsanspruch ist hoch, was sich seitens der Anrufer meistens in einer niedrigen Bereitschaft in der Warteschlange auszuhalten niederschlägt, und damit letztlich in hohen Abbruchquoten mündet.

¹ Vgl. Radtke (2001), S. 56.

² Vgl. Kesting (2004), S. 6.

Für die einzelnen Call Center-Betreiber ist dabei problematisch, dass der hohe Wettbewerbs- und Konkurrenzdruck dazu führte, dass sich eine Profilierung am Markt lediglich noch über die *kommunikative Qualität* ergeben kann, zumal in preislicher Hinsicht die Talsohle bereits erreicht ist. Gleichzeitig sehen sich die Auskunftsanbieter mit zunehmenden Kundenforderungen konfrontiert, da die Leistungen nicht nur regional begrenzt nachgefragt werden, sondern der Informationsstand der Kunden aufgrund intensiver Werbemaßnahmen aller Wettbewerber am Markt höher ist. Die Loyalität gegenüber einen bestimmten Anbieter nimmt ab.

Was den Call Centern noch an Optimierungsmöglichkeiten bleibt, ist die *Optimierung der Kostenstruktur*. Dies wird umso notwendiger, als mittlerweile auch Anbieter mit Sitz im günstigeren Ausland auf den deutschen Markt drängen und dadurch die Wettbewerbsintensität nochmals verschärfen.

Fraglich ist nun, was die Ansatzpunkte zur Senkung der Kosten sind.

Führt man sich die Kostenverteilung vor Augen, so zeigt sich folgendes Bild:³

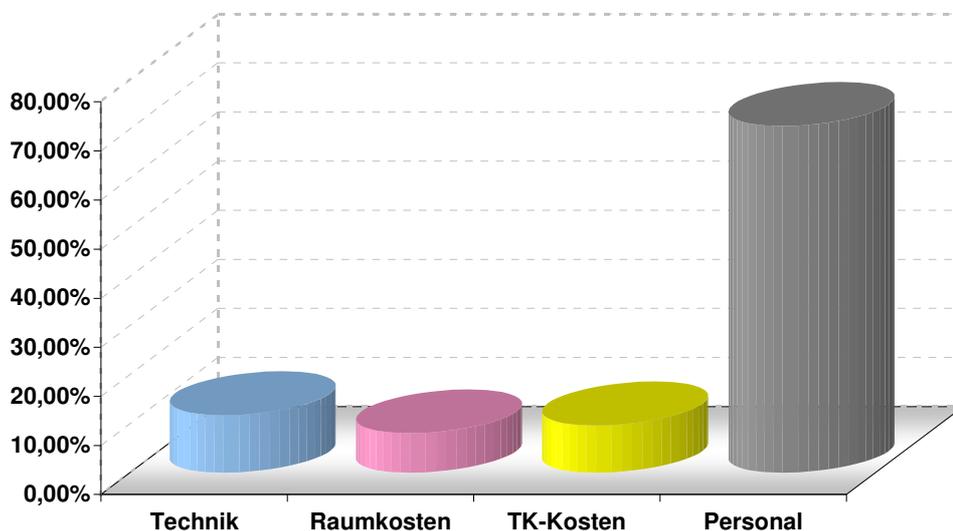


Diagramm 1.1: Kostenstruktur in Call Centern

³ Das Diagramm basiert auf durchschnittlichen Kostenangaben in der Literatur; vgl. hierzu etwa Menzler-Trott/Hasenmaile (2000), S. 129; Michels (1999), S. 164f.

Es wird deutlich, dass die physischen Komponenten wie Technik, Gebäude und Mobiliar und auch die gesamten Telekommunikationsanlagen (TK-Kosten) im Vergleich zu den Personalkosten nur eine untergeordnete Rolle spielen. Das Gros der Kosten entfällt auf die Agenten. Hierin liegt damit auch ein enormes Einsparungspotential, sofern die agentenspezifischen Prozesse optimiert und effizienter gestaltet werden können.

Der Ansatzpunkt zur Optimierung des Personaleinsatzes kann dabei auf zweierlei Ebenen gefunden werden.

Zum einen ist es in strategischer Hinsicht von entscheidender Bedeutung, zu wissen, wie groß das Anrufvolumen an einem bestimmten Tag ist. Die Anruflast bestimmt nämlich letztendlich die Anzahl der benötigten Agenten, wenn ein bestimmter Servicegrad für den Kunden eingehalten werden soll.

Eine *Callprognose* kann also als Kenngröße herangezogen werden, um strategische Entscheidungen, wie die Aufstockung oder Verminderung des Personalstammes oder die zeitliche Planung von Weiterbildungsmaßnahmen für die Operatoren durchzuführen.

Je genauer also die Prognose des Callvolumens ist, umso größer wird die Planungssicherheit und umso weniger müssen kurzfristige Korrekturaktionen, die oftmals sehr kostenintensiv enden können, vorgenommen werden.

In der Praxis läuft diese Prognose meist noch aufgrund von „Erfahrungswerten“ oder eher heuristischen Methoden ab, die lediglich auf langfristigen Durchschnittswerten beruhen.⁴ Verständlicherweise führen derartige Methoden lediglich zu suboptimalen Ergebnissen und werden dem Anspruch einer möglichst genauen Prognose nicht gerecht.

In dieser Arbeit soll das Konzept *künstlicher neuronaler Netze* für die Callprognose ihre Anwendung finden und es soll ihre Geeignetheit für den praktischen Einsatz untersucht werden.

Die zweite Ansatzmöglichkeit zur Optimierung des Personaleinsatzes betrifft die operative Planung, also die konkrete Schichtplanung.

⁴ Vgl. Cleveland/Mayben/Greff (1998), S. 69-71.

Ziel hierbei ist es, in Abhängigkeit der Anruflast und der Call Center-spezifischen Parameter wie Servicezeit- und Ankunftsrate der Calls eine optimale Anzahl an Agenten im Betrieb zu haben, um einerseits den Servicegrad aufrecht erhalten zu können und andererseits die Personalkosten auf ein Minimum zu reduzieren.

Beide Ansatzpunkte sollen daher genauer analysiert und auf empirische Daten eines typischen Inbound Call Centers übertragen werden.

1.2 Gang der Arbeit

Zunächst wird im folgenden Kapitel die Thematik der Call Center genauer erläutert. Dabei sind zunächst die unterschiedlichen Begrifflichkeiten für Call Center zu spezifizieren und eine Fallunterscheidung ist zu treffen. Des Weiteren wird auch kurz auf den technischen Aufbau eingegangen, um aufzuzeigen, welche Stationen ein Anruf intern in einem Call Center zurücklegt und welche Art von Daten dabei gespeichert werden können. Diese Daten liefern letztendlich auch die wichtigen Informationen, die für die Callprognose und zur Planung der Schichtmodelle herangezogen werden können. In diesem zweiten Kapitel werden zudem die wichtigsten Einflussgrößen in einem Call Center vorgestellt und ihre Bedeutung und Interdependenzen mit dem Personaleinsatz aufgezeigt. Der Servicelevel wird hierbei einer genaueren Darstellung widerfahren, zumal diese Größe auch bei der operativen Personaleinsatzplanung eine zentrale Rolle spielen wird.

In Kapitel 3 werden dann die theoretischen Grundlagen für die Prognose der Calldaten gelegt. Hierfür wird das Konzept der künstlichen neuronalen Netze behandelt. Neben der Definition und einem kurzen Bezug des mathematischen Modells zum biologischen Vorbild, wird auch eine mögliche Klassifizierung der künstlichen neuronalen Netze anhand der unterschiedlichen Lernparadigmen gegeben. Im Anschluss daran werden die beiden grundlegenden Lernregeln, nämlich die Hebbsche und die Delta Lernregel, erläutert und die generalisierte Delta Regel allgemein hergeleitet. Da im empirischen Teil der Prognose eine dreischichtige

Netzwerktopologie ihre Anwendung findet, werden in diesem Kapitel auch die konkreten mathematischen Lösungsschritte zur Berechnung von Prognosen in zweistufigen Netzwerken angegeben.

In einem weiteren Schritt werden die künstlichen neuronalen Netze noch einer kritischen Würdigung unterzogen und Lösungsansätze für ihre Schwachstellen aufgezeigt.

Kapitel 4 bildet die Umsetzung der theoretischen Konstrukte neuronaler Netze auf empirische Daten. Damit wird das Callvolumen prognostiziert, wobei zunächst die Rahmenbedingungen zur Prognose dargestellt werden. Hierunter fallen zum einen die Identifizierung von Einflussgrößen auf das Callverhalten und deren statistische Überprüfung auf Geeignetheit. Zum anderen gilt es dann auch eine optimale Modellspezifikation zu treffen, d. h. eine effiziente Netzwerktopologie und geeignete Größen der Netzwerkparameter müssen gefunden werden. Erst dann kann das Training für die vorliegenden Daten gestartet und eine Prognose erstellt werden. Die Ergebnisse werden in einem weiteren Schritt noch auf ihre Güte hin untersucht und einer abschließenden Berteilung unterzogen.

Nachdem die für die strategische Personaleinsatzplanung durchgeführte Prognose abgeschlossen ist, wird dann in Kapitel 5 und 6 auf die operativen Modelle übergegangen.

Hierbei werden in Kapitel 5 zunächst die theoretischen Grundlagen der Warteschlangentheorie erklärt. Im ersten Unterkapitel ist die Bedeutung der Bedientheorie speziell für die Call Center dargestellt, bevor die Definition und Aufstellung der Eigenschaften und Kenngrößen von Warteschlangenmodelle erläutert werden. Vor allem auf die Bedeutung der Exponentialverteilung wird in diesem Zusammenhang ausführlicher eingegangen. Die Systematik der Kendall-Symbolik findet ebenso wie die Konzeption der Geburts- und Sterbeprozesse der Warteschlangentheorie ihren Eingang. Nachdem die Grundlagen geschaffen worden sind, wird dann das zur Personaleinsatzplanung in der Praxis eingesetzte Erlang C-Modell theoretisch hergeleitet. Neben der Darstellung des notwendigen Annahmensystems werden auch die für die Einsatzplanung notwendigen Kennzahlen

berechnet, wobei stets auf die Bedeutung für den praktischen Anwendungsfall in Call Centern hingewiesen wird.

Abschließend wird für dieses spezielle Modell der Warteschlangentheorie eine kritische Würdigung angeführt.

Kapitel 6 befasst sich mit der praktischen Umsetzbarkeit des Erlang C-Modells. Dabei wird deutlich, dass die wesentlichen Prämissen des theoretischen Modells in der Praxis nicht erfüllt sind und damit Verzerrungen bei der Personaleinsatzplanung resultieren. Durch eine Simulationsstudie, in der diese konkreten Annahmeverletzungen berücksichtigt werden, wird unter realen Bedingungen der Call Center Betrieb simuliert und auf Basis dieser Ergebnisse ein optimaler Personaleinsatzplan entworfen. In einem weiteren Schritt wird auf Grundlage der Simulationsstudie ein effizientes Schichtmodell berechnet, das abschließend mit dem Personaleinsatzplan verglichen wird, den das starre Erlang C-Modell berechnet hätte.

In Kapitel 7 werden die wesentlichen Ergebnisse der Arbeit zusammengefasst und die Bedeutung der Resultate für die Praxis dargestellt.

Kapitel 2: Call Centers

2.1 Arten von Call Centern

Call Centers werden im Allgemeinen als *technisch-organisatorische Einheiten* beschrieben, in denen „mehrere Mitarbeiter zur systematischen Durchführung einer größeren Zahl von Telefongesprächen zusammengezogen werden“⁵.

Im Wesentlichen handelt es sich also um eine *kommunikative* Dienstleistung für den Kunden, um so mit dem Unternehmen schnell und möglichst bequem in Kontakt zu treten. Zwar steht hier das Telefon als zentrales Instrument zur Kontaktaufnahme im Zentrum, allerdings kann die Dienstleistung auch über Fax oder Email erbracht werden.

In den letzten Jahren erfuhr dabei diese Art der Dienstleistung einen großen Aufschwung, zumal sowohl der öffentliche, als auch der private Sektor in Form von Versorgungsbetrieben und Notrufzentralen bzw. der Versandhandel, Versicherungen und Banken sich entsprechende Call Centers als Instrument der Kundenbetreuung immer mehr zu Nutze machen und dadurch Kundenbindungsstrategien aufzubauen versuchen. Gerade Letzteres wird unter Berücksichtigung von zunehmendem Wettbewerb auf allen Märkten, dem Wandel zur Dienstleistungsgesellschaft und der Veränderung von wettbewerblichen Rahmenbedingungen immer wichtiger, so dass neue Dienstleistungsangebote, wie Total Customer Care, Help-Desk, Servicepool oder Servicehotline mehr und mehr zur strategischen Kundenbindung eingesetzt werden.⁶

Grundsätzlich kann im Zusammenhang mit Call Centern zwischen einem so genannten *Inbound* (oder auch „*Incoming*“⁷) und einem *Outbound* Call Center unterschieden werden.⁸

Als Inbound Call Center werden jene Dienstleister bezeichnet, bei denen die Anrufe von außen, also ohne Einflussmöglichkeit des Centers, ankommen, während Outbound Dienstleistungen jene Gespräche umfassen, die aktiv vom Call Center

⁵ Helber/Stolletz (2004b), S. 68.

⁶ Vgl. Böse/Flieger (1999), S. 13f.

⁷ Wiencke/Koke (1999), S.12.

⁸ Vgl. u.a. Helber/Stolletz (2004a), S. 4f. und Thieme/Steffen (1999), S. 120f.

initiiert werden. Hierzu zählen etwa Anrufe zu Marktforschungszwecken, Kundenzufriedenheitsanalysen oder auch Verkaufsgespräche.⁹

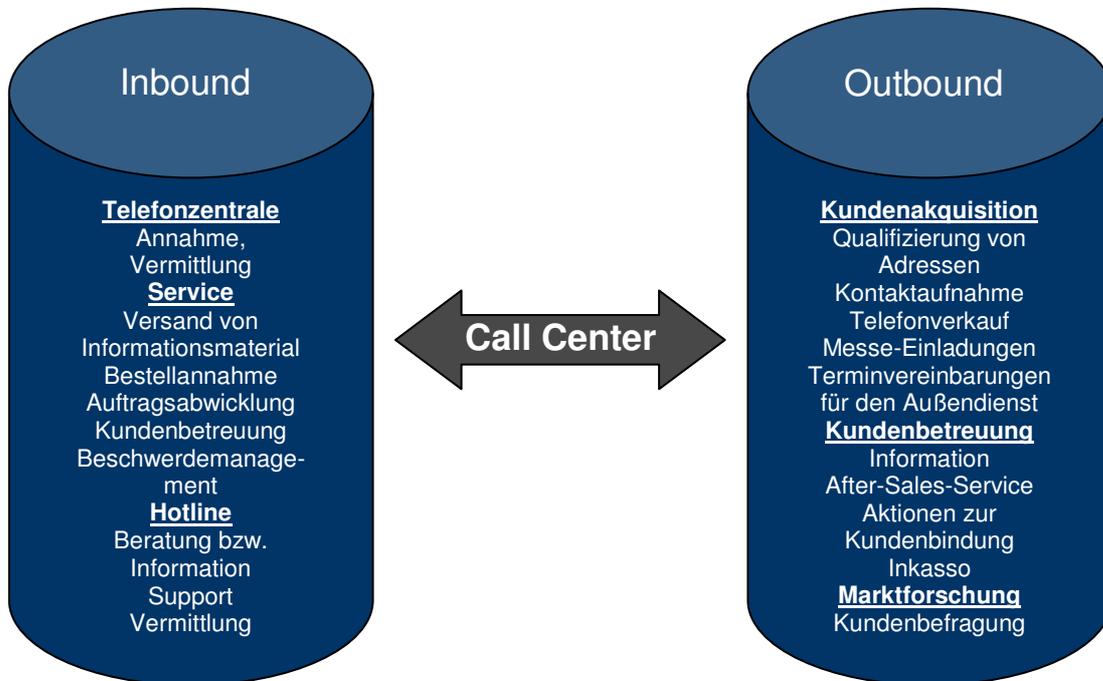


Abbildung 2.1: Kategorisierung von Call Centern

In dieser Arbeit wird der Teil der Outbound Call Center ausgegrenzt, zumal der Personaleinsatz in diesem Bereich flexibler und planbarer ist, da die Gespräche hier aktiv von einer Mitarbeitergruppe an Telefonarbeitsplätzen geführt werden und dadurch die Gesprächsinhalte auch in einem festgelegten und vor allem durch das Call Center steuerbaren Rahmen ablaufen.

Viel interessanter hingegen ist die Personaleinsatzplanung im Inbound Call Center.

Der Unterschied zwischen Inbound und Outbound Call Center postuliert auch das wesentliche Problem der Personaleinsatzplanung: Die Anrufe sind nicht mehr vom Call Center aus steuerbar und erfordern eine möglichst genaue Prognose!

⁹ Vgl. Wiencke/Koke (1999), S.12 f.

Bevor das Augenmerk allerdings auf das Callvolumen und dessen Prognose fällt, muss noch die Grundstruktur für die Planung abgesteckt werden, zumal hier wichtige Kennzahlen festzulegen sind, die im späteren Schritt der Analyse und Prognose eine wichtige Rolle spielen werden.

2.2 Technische Ausstattung in Call Centern

Um die Funktionsweise von Call Centern besser verstehen zu können, werden im Anschluss allgemein die wichtigsten *technischen Bestandteile*, die sowohl für In- als auch für Outbound Centern gelten, kurz näher erläutert.

Im Allgemeinen ist die Arbeitsumgebung eines Call Centers ein Großraumbüro mit vielen abgeteilten Arbeitsplätzen, an denen die Agenten mit Headsets sitzen und die Anrufe entgegennehmen.

Unten stehende Grafik gibt bereits einen Überblick über die wichtigsten *Komponenten* im Call Center.

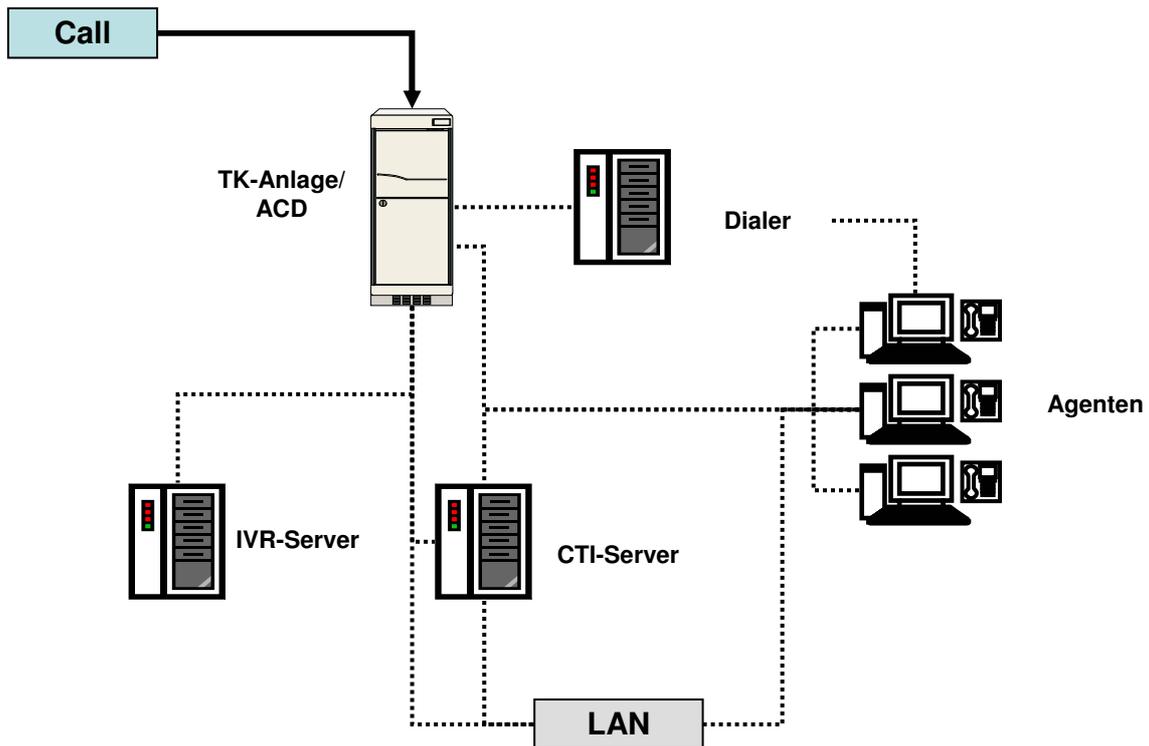


Abbildung 2.2: Technische Komponenten eines Call Centers

Der Kernbaustein eines jeden Call Centers ist die *Telekommunikationsanlage* (TK-Anlage). Sie stellt im Prinzip die Verbindung zwischen dem ankommenden Call und einem beliebigen Agenten her. Für die Verteilung von Anrufen auf bestimmte Mitarbeiter ist die *ACD* (*Automatic Call Distributor*)-Anlage zuständig. Während die Telekommunikationsanlage gezielt zwei Personen miteinander verbindet, soll die ACD einen ankommenden Anruf mit einer Person aus einer Gruppe verbinden. Sie verfügt über Funktionen zur Steuerung und Kontrolle der optimalen Auslastung eines Call Centers. Da sie für professionelle Anforderungen im Call Center entwickelt wurden, vereinbaren sie hohe Verkehrsleistung¹⁰ mit umfangreichen Statistikfunktionen. Hier werden auch die notwendigen Datensätze generiert, die später zu Planungs- und Kontrollzwecken wiederum herangezogen werden. Die ACD kann auch als Erweiterung der Telekommunikationsanlage angesehen werden, wobei es gerade für größere Call Center auch eigenständige ACD-Systeme bestehen und diese dann ausschließlich für die Anrufverteilung zuständig sind.

¹⁰ Die Verkehrsleistung definiert sich dabei über die Anzahl der Calls pro Stunde.

Das ACD-System und die Telekommunikationsanlage bilden im Call Center keine Inseln, sondern stehen in enger Verbindung mit der Informationstechnologie des Unternehmens. Dass diese Zusammenarbeit auch reibungslos funktioniert, stellt die CTI („Computer Telephony Integration“¹¹) sicher. Sie bildet damit die Schnittstelle von Telefon und den Funktionen der Datenverarbeitung und erlaubt dem Operator serviceorientiert zu arbeiten. Sobald der Anrufer nämlich identifiziert ist – sei es durch seine Telefonnummer oder durch Eingabe seines PINs – können sämtliche über den Kunden abgespeicherten Daten am Bildschirm des Agenten angezeigt werden. Der Agent kann so nachvollziehen, was der Kunde mit anderen Agenten bereits besprochen hat ohne dazu erneut Rücksprache halten zu müssen. Durch die CTI bieten sich Möglichkeiten der Effizienzsteigerung und Service-Verbesserung für den Betreiber, wobei hierunter Schlagwörter wie Kundenbindung und Kostensenkung fallen.

Interaktive Sprachverarbeitungssysteme (IVR, Interactive Voice Response) hingegen erweitern die Dialogmöglichkeiten mit dem Anrufer und die Agenten werden zudem von Routineauskünften entlastet, zumal der Anrufer durch einen sprachgesteuerten Computerdialog begrüßt wird und ihm verschiedene Möglichkeiten angeboten werden, die per Tastendruck oder Sprache ausgewählt werden können, um so automatisch an das für sein Anliegen zuständige Agententeam weitergeleitet zu werden. Natürlich kann es auch hier zu Verständigungsproblemen kommen, gerade wenn das Mittel der automatischen Spracherkennung eingesetzt wird, aus diesem Grund sollte hier auch immer eine Verzweigung zu einem Agenten des Call Centers gegeben sein.

Das Komplementär zum ACD-System im Inbound Call Center ist die automatische Anwahlhilfe (*Dialer*) im Outbound-Betrieb. Die zentrale Aufgabe dieser Systeme ist die schnelle Abarbeitung umfangreicher Telefonnummernbestände und sie sorgen so für eine optimale Auslastung. Sie ersetzen damit auch die langwierigen manuellen Rufnummerneingaben und die Anrufe werden erst dann zugestellt, wenn sich der Angerufene meldet. Des Weiteren erkennt der Dialer automatisch, wenn die angerufene Nummer besetzt ist und baut dann eine andere, neue Verbindung auf.

¹¹ Vgl. u. a. Thieme/ Steffen (1999), S.94f; Menzler-Trott/Hasenmaile (2000), S.32f.

Die eben beschriebenen Komponenten werden alle durch ein *Local Area Network (LAN)* miteinander verbunden und können so einen effizienten Zugriff von den Agenten sicherstellen.

2.3 Statistische Kennzahlen im Call Center

2.3.1 Generierte Daten aus der ACD-Anlage

Die neuesten Telefon- bzw. ACD-Anlagen liefern mittlerweile eine Vielzahl an statistischen Daten, die dann wiederum herangezogen werden können, um Arbeitsprozesse und Abläufe im Berichtswesen zu optimieren und um Prognosemodelle für die Entwicklung der Callverläufe aufzustellen. Mit Hilfe dieser Daten bzw. Kennzahlen können des weiteren Reports für die Bereiche *Billing*, *Marketing* und *Produkt Management* erstellt werden und Fehleranalyse durchgeführt werden. Entscheidend für die jeweiligen Reports und Analysen sind allerdings die *Rohdaten*, die meistens in tabellarischer Form dargestellt werden. Diese Rohdaten bilden die Grundlage für umfangreiche Auswertungsmöglichkeiten. Um dies bewerkstelligen zu können, müssen die Daten allerdings zunächst in ein speziell dafür entwickeltes Programm geladen werden.¹² Aus datenschutzrechtlicher Sicht ergibt sich hier allerdings ein Problem, denn die Rohdaten aus der ACD-Anlage sind nicht anonymisiert, das heißt es ist jeweils die Telefonnummer des Anrufers ersichtlich, als auch die Nummer mit der er weiter verbunden wurde. Bevor also umfangreichere Reports angefertigt werden können, müssen die Daten anonymisiert werden. Erst dann ist auch eine dauerhafte Speicherung der Daten erlaubt. Die Rohdaten dürfen generell nur zu abrechnungstechnischen Zwecken temporär gespeichert werden.¹³

¹² Das hier beschriebene Programm zur Bearbeitung von Rohdaten aus der ACD-Anlage wird bei Infoportal „CSG“ (Call Statistics Generator) genannt. Ähnliche Softwareprogramme sind in allen Call Centern im Einsatz, wobei sich die Programme lediglich geringfügig in ihren Spezifikationen unterscheiden.

¹³ Im §5 Abs. 1 bis Abs. 3 TDSV (Telekommunikationsdienstunternehmen-Datenschutzverordnung) steht zum Thema Datensicherung und -verarbeitung, dass während einer Verbindung

Folgende Grafik zeigt, wie Rohdaten aus der ACD-Anlage gespeichert und wiedergegeben werden und in welchem Benutzerinterface weitere Analysen getätigt werden können:

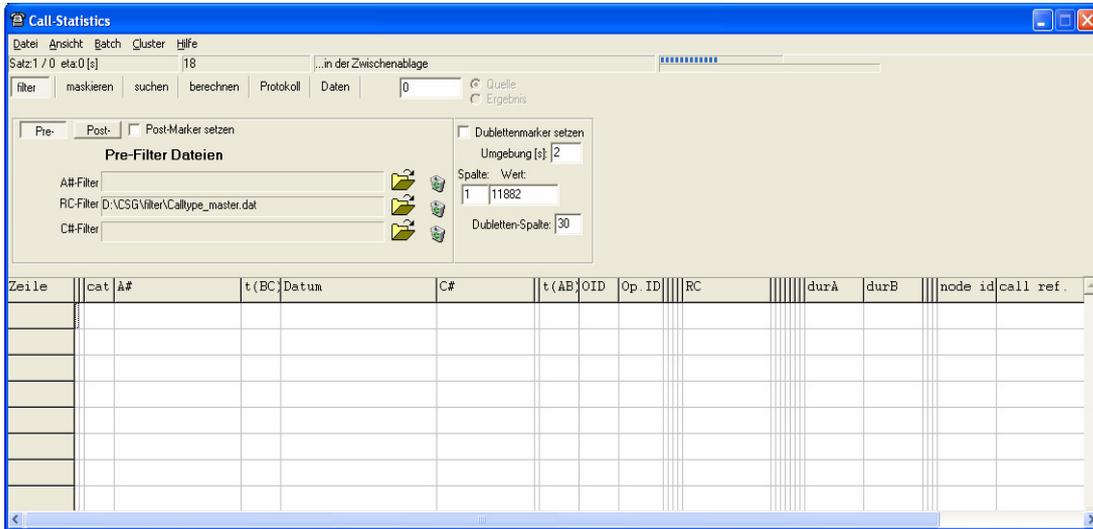


Abbildung 2.3: Bearbeitungs- und Eingabemaske für die Rohdaten aus der ACD-Anlage

In diesem speziellen Programm zur Verwaltung der Calldaten sind zahlreiche Einstellungen und Auswertungen möglich. Die wichtigsten statistischen Kennzahlen sind dabei in folgender Übersicht zusammengefasst:

| | |
|--------------|--|
| t(BC) | Gesprächsdauer zwischen A-Teilnehmer (Anrufer) und dem Agenten |
| Datum | Zeitstempel (Datum und Uhrzeit des Anrufeingangs) |
| t(AB) | Gesprächsdauer der Weitervermittlung |
| Op.ID | Operatoridentifikationsnummer |
| durA | Duration A-subscriber (Zeit, in der der A- |

personenbezogene Daten erhoben und gegebenenfalls auch über das Ende der Verbindung hinaus gespeichert werden dürfen, sofern es für Zwecke erforderlich ist, die durch die TDSV genehmigt sind. Hierunter zählen gem. § 7 Abs. 1 TDSV die Tatbestände der Störung und Fehlern an Telefonanlagen, das Aufdecken von Erschleichung von Leistungen und sonstiger rechtswidriger Inanspruchnahme öffentlicher Telekommunikationsnetze. Im Übrigen sind die Verbindungsdaten nach dem Ende der Verbindung zu löschen, oder zu anonymisieren.

| | |
|-------------|---|
| | Teilnehmer am Gespräch beteiligt ist) |
| durB | Duration B-subscriber (Zeit, in der der B-Teilnehmer am Gespräch beteiligt ist) |

Tabelle 2.1: Übersicht über die wichtigsten statistischen Daten aus der ACD-Anlage¹⁴

Der Zusammenhang zwischen den einzelnen Gesprächszeiten ist dabei wie folgt:

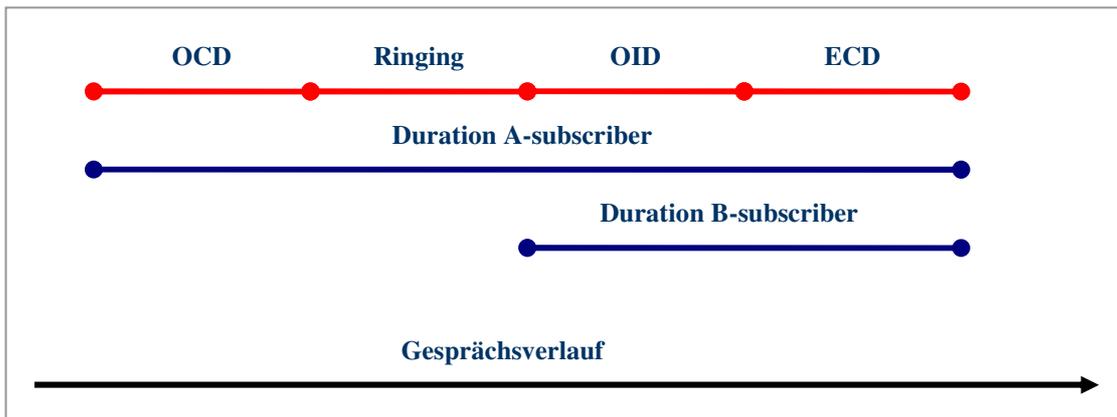


Abbildung 2.4: Darstellung der zu unterscheidenden Gesprächszeiten

Als *OCD* wird dabei die *Operator Conversation Duration* bezeichnet, also die Gesprächsdauer, in der der Operator seine Ansage macht und mit dem Anrufer spricht.

Die *Ringling-Time* umfasst jene Zeitspanne, in der das Gespräch gehalten wird („*holding-time*“) und der B-Teilnehmer (also die Zielperson für den A-Teilnehmer) angerufen wird. Entscheidend ist, dass diese *holding-time* in der Regel nicht von der gesamten Gesprächsdauer abgezogen und demnach dem Kunden auch in Rechnung gestellt wird. Die *Operator Intervention Duration (OID)* bezeichnet weiterhin die Ansprache des Operators beim B-Teilnehmer, damit dieser darüber informiert wird, dass eine Weiterverbindung stattfindet. Die *Elapsed Conversation Duration (ECD)* umfasst schließlich noch die Zeitspanne, in der der Operator

¹⁴ Die Begriffe wurden aus internen Unterlagen von Infoportal entnommen.

nochmals zum A-Teilehmer zurückkehren muss, um ihn zu informieren, dass die Verbindung mit dem gewünschten Gesprächspartner nun zustande kommt.

Wie bereits erwähnt, liefert die ACD-Anlage in 15 Minutenintervallen diese Rohdaten und speichert sie dementsprechend ab. Diese noch nicht aufbereiteten Daten ermöglichen in weiteren Schritten, eine Vielzahl an zusätzlichen Kennzahlen zu berechnen, die im Weiteren für die Performancebeurteilung des Call Centers von entscheidender Bedeutung sind. Auf diese Kennzahlen wird in den folgenden Kapiteln genauer eingegangen.

2.3.2 Die Erreichbarkeit

Die *Erreichbarkeit* des Call Centers durch die Kunden ist das zentrale Maß, an dem es sich zu orientieren gilt. Prinzipiell sollte natürlich eine hohe Erreichbarkeit gewährleistet werden, allerdings sieht sich das Call Center mit dem Problem konfrontiert, dass die Anrufe nicht gleichmäßig über den Tag verteilt eingeht, sondern zufällig erfolgen. Es kommt dabei zu sog. „*Peaks*“¹⁵ bzw. Schwankungen im Anrufvolumen, die zwar global auf eine bestimmte Tageszeit zurückzuführen sind, allerdings kann nicht genau vorhergesagt werden, wann ein Anruf eingeht. Das Anrufverhalten der Kunden ist demnach willkürlich und genau dieser Umstand macht es so schwierig, die Erreichbarkeit immer auf höchstem Niveau zu halten. Schließlich ist mit dieser Zielgröße auch immer ein gewisses Dilemma verbunden, denn sind zu wenige Agenten für eine Schicht eingeplant, dann erhöht sich die Wartezeit für die Anrufer und damit sinkt der Grad der Erreichbarkeit. Stehen allerdings zu viele Agenten zur Verfügung, dann ist das Call Center zwar schneller erreichbar, aber die Mitarbeiter haben eine zu große „*Idle-Time*“¹⁶, d. h. sie sind unterausgelastet und warten förmlich auf Anrufe. Dieser Umstand lässt allerdings die Personalkosten wiederum in die Höhe schnellen.

¹⁵ Vgl. hierzu die weiteren Ausführungen in Kapitel 4.2.

¹⁶ Bodin/Dawson (2002), S. 93.

Somit ist es von großer Wichtigkeit, dass die Anzahl der Operatoren möglichst genau der Anruflast entsprechend angepasst wird, was jedoch eine detaillierte und umfassende Analyse der Callperformance voraussetzt.

Das eben beschriebene Dilemma zwischen Anruflast und Anzahl der Agenten hat zur Folge, dass ein bestimmter Servicelevel festgelegt werden muss, an dem sich das Call Center messen lassen muss.

2.3.3 Der Servicelevel

Der *Servicelevel* ist im Grunde die logische Schlussfolgerung des Dilemmas der Erreichbarkeit und Personalkosten, und bildet im Call Center eine weitere Kenngröße von großer Wichtigkeit. Der Servicelevel wird auch häufig als Messinstrument herangezogen, wenn es darum geht das Leistungsniveau eines Call Centers zu bewerten.¹⁷ Hinter dieser Größe verbirgt sich folgende Aussage:

„Wie viel Prozent der Anrufer können innerhalb eines vorgegebenen Zeitintervalls durch das Call Center bearbeitet werden.“¹⁸

Ein geplanter Servicelevel von 90/20 würde demnach bedeuten, dass 90% der Anrufe innerhalb von 20 Sekunden angenommen werden. Umgekehrt könnte man demnach auch argumentieren, dass 10% der Anrufer länger als 20 Sekunden in der Warteschlange warten müssen, bis sie einen Agenten erreichen.

Die drei Bestimmungsfaktoren dieser Messgröße sind demnach:¹⁹

- der prozentuale Anteil der Anrufer, die einen Operator erreichen,
- das Zeitintervall, innerhalb dessen die Anrufe vom Agenten angenommen werden,
- der Bezugszeitraum, innerhalb dessen der Servicelevel überwacht werden muss.

¹⁷ Vgl. Thieme/Steffen (1999), S. 146.

¹⁸ Vgl. Cleveland/Mayben/Greff (1998), S. 38.

¹⁹ Vgl. Wiencke/Koke (1999), S. 61.

Den „richtigen“ Servicelevel festzulegen, bleibt prinzipiell jedem Call Center selber überlassen, allerdings sind hierbei noch ein paar Aspekte zu beachten, wie die Wartetoleranz der Anrufer, die subjektive und objektive Wartezeit und die Beachtung der Kosten im Call Center.

2.3.4 Die Wartetoleranz der Anrufer

Grundsätzlich lassen sich Warteschlangen unterscheiden in „sichtbare“ und „unsichtbare“ Warteschlangen²⁰, wobei sich die Wartetoleranz in beiden Fällen deutlich voneinander unterscheiden. Während im Call Center die Warteschlangenlänge für den Kunden nicht ersichtlich ist, sinkt hier die Wartebereitschaft mit jeder Sekunde, die er nicht einen Operator erreicht. Genau umgekehrt verhält sich die Wartebereitschaft bei sichtbaren Warteschlangen, wie es etwa bei Bankschaltern der Fall ist. Je länger er wartet und je kürzer die Schlange vor ihm wird, um so größer wird auch seine Wartetoleranz, denn er sieht, dass die Menschen vor ihm weniger werden und er bald an der Reihe ist. Es kann also gesagt werden, dass bei sichtbaren Warteschlangen, die Wartetoleranz in der Regel höher ist, als bei unsichtbaren Queues. Einige Call Centers versuchen daher ihre elektronische, unsichtbare Warteschlange sichtbar zu machen, in dem sie dem Kunden darüber informieren, wie lange es voraussichtlich noch dauern wird, bis er einen freien Operator erreicht. Derartige „Queue-Jockeys“²¹, die in Echtzeit die jeweilige Queue-Länge mitteilen, waren die Vorreiter der modernen „IQueues“, die Anfang der 90er Jahre schließlich Einzug in den ACD-Anlagen hielten und die geschätzte Wartedauer angeben.

Beeinflusst wird die Wartetoleranz der Kunden zudem durch Faktoren, die nicht im direkten Einflussbereich des jeweiligen Call Centers sind. Hierzu zählen unter anderem der *Motivationsgrad der Anrufer* (wie wichtig oder dringend ist es, dass der Anrufer das Call Center erreicht und eine Lösung für sein Problem findet), *Alternativen* (ist es notwendig, dass der Kunde gerade dieses Call Center erreicht,

²⁰ Vgl. u. a. Thieme/Steffen (1999), S. 144; Wiencke/Koke (1999), S. 61 und Cleveland/Mayben/Greff (1998), S. 28f.

²¹ Vgl. hierzu und im Folgenden Cleveland/Mayben/Greff (1998), S. 29-31.

oder kann auch ein anderes Call Center eine Lösung für sein Problem anbieten?), der *Servicelevel der Konkurrenz* (ist dieser bei der Konkurrenz hoch, wird der Kunde tendenziell eher darauf ausweichen), der *Erwartungshorizont* (hat das Call Center eine sehr gute Reputation, wird der Anrufer länger bereit sein zu warten), die *verfügbare Zeit* des Anrufers, die *Gebührenübernahme* (tendenziell sind die Kunden dann eher bereit länger zu warten, wenn der Anruf gebührenfrei ist) und schließlich das *Wohlbefinden* des Anrufers an sich (auch hier gilt, dass ein Kunde mit guter Stimmung eine gewisse Zeit in der Warteschleife eher hinnimmt, als ein schlecht Gelaunter).

2.3.5 Subjektive versus objektive Wartezeit

Eng verwandt mit der Wartetoleranz der Anrufer ist auch die Unterscheidung zwischen *subjektiver* und *objektiver Wartezeit*, wobei die subjektive Wartezeit gemessen an der tatsächlichen (objektiven) Wartezeit überproportional ansteigt, je länger ein Kunde schon in der Warteschlange ist. Grafisch lässt sich dies folgendermaßen zusammenfassen:

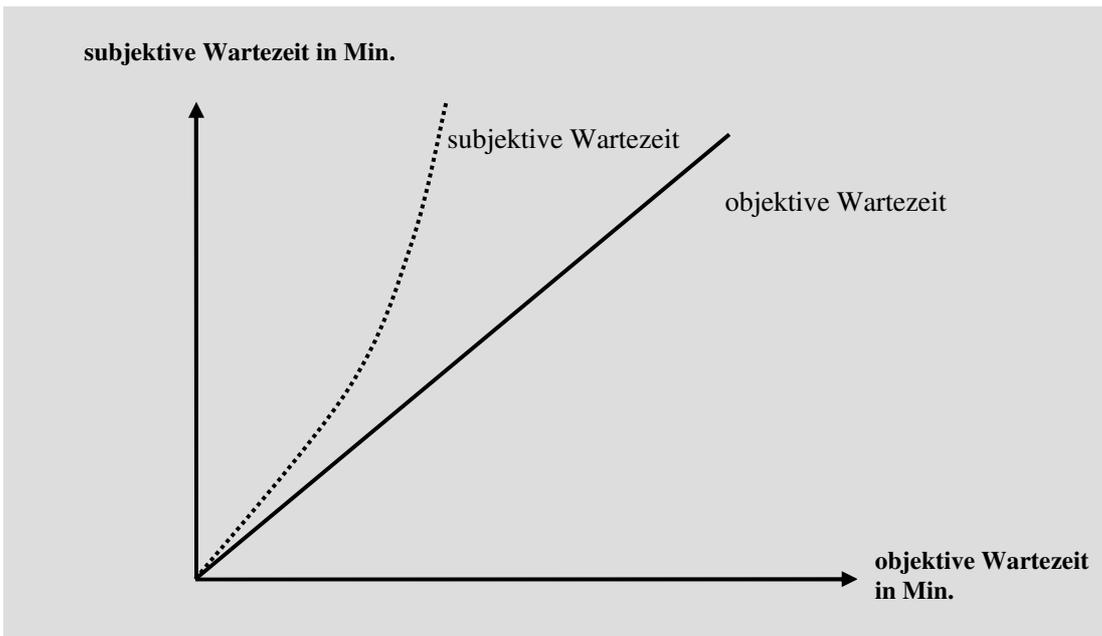


Abbildung 2.5: Verlauf der subjektiven und objektiven Wartezeit

Subjektiv wird also die Wartezeit immer länger eingeschätzt, als es tatsächlich der Fall ist. Besonders in Wartesystemen, in denen man die Schlängellänge eben nicht sehen kann, ist die Kluft zwischen subjektiv wahrgenommener und tatsächlicher Wartezeit noch deutlicher. Auch dieser Umstand kann letztendlich rasch zu einem Abbruch des Anrufs führen.

2.3.6 Der Einfluss des Servicelevels auf die Kosten im Call Center

Wie bereits angesprochen, ist mit dem Grad der Erreichbarkeit auch immer ein bestimmter Personaleinsatz und damit auch Personalkosten verbunden. Je höher der Servicelevel also angesetzt wird, umso größer sind auch die Kosten durch den vermehrten Personaleinsatz. Dieser Zusammenhang lässt sich auch leicht empirisch mit den zur Verfügung stehenden Daten beweisen²².

²² Die Datenbasis für die folgende Darstellung ist ein durchschnittlicher Werktag im September 2004. Als Berechnungsgrundlage des Servicelevels wurde die Erlang-C Formel verwendet, wobei an diesem Tag eine Arbeitslast von 27,19 Erlang vorlag. Zur Berechnung und Bedeutung der Erlang-C-Formel sei auf die entsprechenden Kapiteln später in der Arbeit verwiesen.

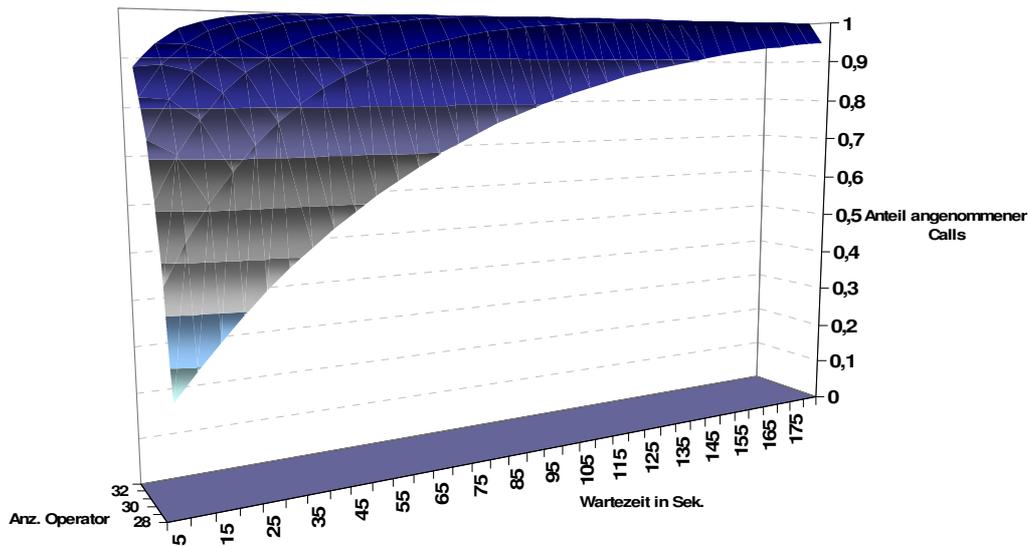


Diagramm 2.1: Zusammenhang zwischen Servicelevel und Anzahl der benötigten Operatoren

Das obige Diagramm zeigt das Dilemma von Servicegrad (Anteil angenommener Calls) und Anzahl der benötigten Agenten, um das Serviceniveau auch halten zu können. Es kann in Abhängigkeit der Anzahl der Agenten und der Wartezeit der Kunden, der Anteil der angenommenen Calls abgelesen werden. Damit resultiert ein nicht linearer Zusammenhang, der folgende Konsequenzen nach sich zieht:

Betrachtet wird in diesem Beispiel eine Agentenzahl zwischen 28 und 33; die Wartezeit der Anrufer variiert zwischen fünf und 180 Sekunden. Wird die Anzahl der Operatoren bei einem bestimmten Wert fixiert, so kann in Abhängigkeit der Wartezeit der Servicegrad abgelesen werden, bzw. umgekehrt, für einen angestrebten Servicegrad kann durch Variation der Wartezeit die benötigte Anzahl an Agenten bestimmt werden.

Logischerweise erhöht sich mit zunehmender Wartezeit die Servicewahrscheinlichkeit, also die Wahrscheinlichkeit, dass der Kunde bedient wird. Im zweidimensionalen Raum würden damit entsprechend die Höhenlinien (die jeweils einer anderen Anzahl an Operator im Call Center entsprechen) in ein Wartezeit-Servicegrad Diagramm projiziert werden.

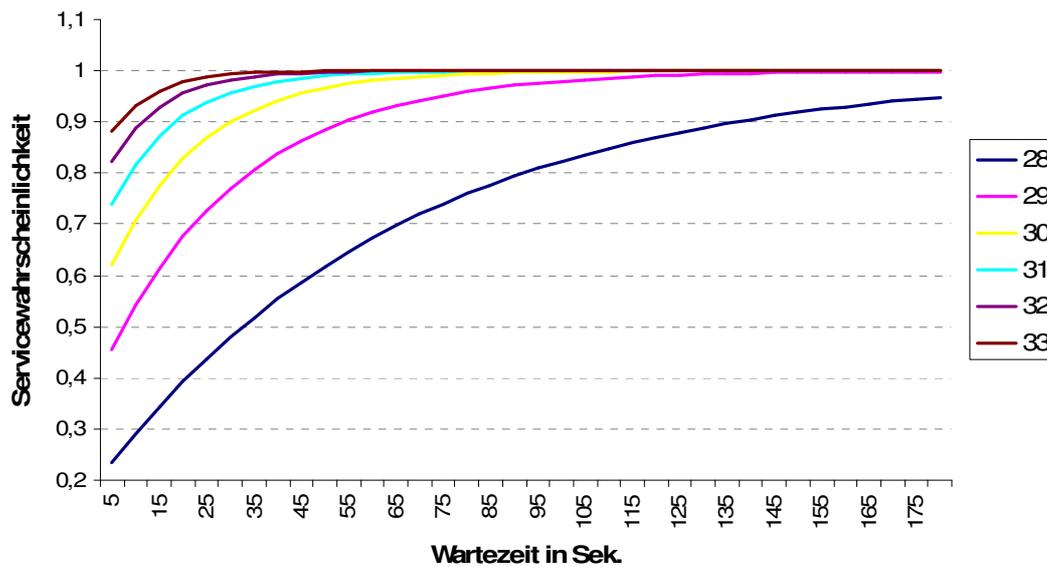


Diagramm 2.2: Zusammenhang zwischen Wartezeit und Servicewahrscheinlichkeit

Wird etwa von einer Wartezeit von 20 Sekunden ausgegangen, dann könnte bei 28 Agenten eine Servicewahrscheinlichkeit von 39% erzielt werden. Bei 29 Agenten läge diese Wahrscheinlichkeit schon bei 61% und bei 30 Agenten bei 82%. Es wird schon deutlich, dass eine weitere Erhöhung der Operatorenzahl auf 31, 32 und 33 eine nur unterproportionale Zunahme der Servicewahrscheinlichkeit zur Folge hätte, nämlich 91%, 95% und 97%. Es lässt sich demnach festhalten, dass mit dem Anstieg der Agentenzahl im Call Center immer eine Erhöhung des Servicelevels einhergeht und das unabhängig von der Wartezeitschranke.

Die Auswirkung des Einsatzes von ein paar mehr oder weniger Agenten, zeigt nachstehendes Diagramm.

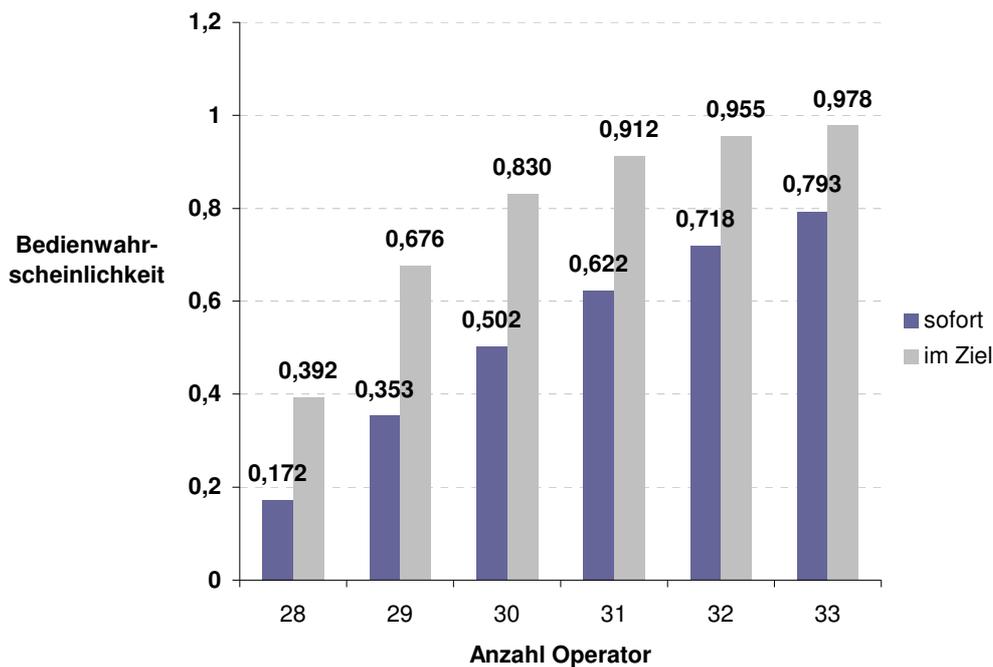


Diagramm 2.3: Zunahme des Servicelevels bei Einsatz zusätzlicher Agenten

Ausgangspunkt ist ein Servicelevel von 80/20, das heißt 80% der Anrufer sollten innerhalb von 20 Sekunden („im Ziel“) bearbeitet werden. Bei einer unterstellten Arbeitslast von 27,19 Erlang wären 30 Agenten nötig, um dieses Servicelevel aufrechtzuerhalten. Das Hinzufügen eines weiteren Operators würde in einem Anstieg des Servicelevels auf 91,2% resultieren, d. h. das Bedienungsniveau würde um 8,2% steigen. Ein zusätzlicher Agent würde den Servicelevel um weitere 4,3% auf 95,5% ansteigen lassen. Wird allerdings einer der 30 Ausgangsmitarbeiter entfernt, dann würde der Servicelevel sogar um 15,4% fallen.

Dies zeigt, dass jeder zusätzlich eingesetzte Agent den Servicelevel nur noch wenig erhöht (abnehmender Grenznutzen oder „Law of diminishing returns“)²³, aber demgegenüber hohe Personalkosten verursacht. Ein leicht unterbesetztes Call Center hingegen kostet viel im Service und bringt nur wenig an Kosteneinsparungen. Dieses Dilemma gilt es letztendlich in der Personaleinsatzplanung zu bewältigen.

²³ Wiencke/Koke (1999), S. 75.

2.3.7 Die Mitarbeiterauslastung

Ein weiterer Einflussfaktor auf die Leistungsfähigkeit eines Call Centers ist durch die Auslastung der Agenten gegeben. Dabei beschreibt die Mitarbeiterauslastung den Anteil der Zeit, in der die Agenten mit Anruferarbeit beschäftigt sind, oder anders ausgedrückt²⁴:

$$\text{Agentenauslastung} = \frac{\text{Zeit beschäftigt mit Anruferarbeit}}{\text{betrachtetes Zeitintervall}} \cdot 100.$$

Der Zusammenhang mit dem Servicelevel kann auch hier durch ein einfaches Beispiel verdeutlicht werden.²⁵

| # Agents | SLA% | % Queued | Aband'd | Utilisation | ASA (secs) | Queue Time (secs) | Average Queue |
|----------|------|----------|---------|-------------|------------|-------------------|---------------|
| 28 | 0% | 100% | 100% | 100% | 179 | 179 | 99 |
| 29 | 56% | 85% | 65% | 98% | 61 | 72 | 35 |
| 30 | 87% | 67% | 34% | 94% | 20 | 30 | 11 |
| 31 | 96% | 52% | 18% | 91% | 10 | 19 | 5 |
| 32 | 99% | 40% | 9% | 88% | 5 | 14 | 3 |
| 33 | 100% | 30% | 5% | 86% | 3 | 11 | 2 |
| 34 | 100% | 22% | 2% | 83% | 2 | 9 | 1 |
| 35 | 100% | 16% | 1% | 81% | 1 | 7 | 1 |
| 36 | 100% | 12% | 1% | 79% | 1 | 6 | 0 |
| 37 | 100% | 8% | 0% | 77% | 0 | 6 | 0 |

Tabelle 2.2: Zusammenhang zwischen Servicelevel und Auslastung

Bei einer Agentenzahl von 30 kann ein Servicelevel (SLA%) von 87% bei 20 Sekunden realisiert werden. Hierbei ist anzumerken, dass die Reaktionszeit von 20 Sekunden, bis ein Anruf angenommen wird, als fixer Parameter ins Modell aufgenommen wurde. Die *durchschnittliche Geschwindigkeit* bis ein Call

²⁴ Vgl. Helber/Stolletz (2004a), S. 335.

²⁵ Das Anwendungsbeispiel basiert auf der Erlang-C Formel. Es sei hierbei auf das Kapitel 5 verwiesen. Als Grundparameter dienen hier eine mittlere Servicezeit von 47,39 Sekunden und einem Anrufvolumen von 2038 Calls pro Stunde. Diese Werte wurden aus den Rohdaten der ACD-Anlage ermittelt, wobei es sich um die Durchschnittswerte zwischen 12 und 13 Uhr an einem normalen Werktag im September 2004 handelt.

angenommen wird (ASA) liegt auch hier bei 20 Sekunden, während der Anteil der Anrufe, die in eine Warteschleife eingestellt werden (*%Queued*) bei 67% liegt und mit einer Auflegrate (*Aband´d*) von 34% zu rechnen ist. Die Queue-Time, also die durchschnittliche Wartezeit in der Warteschlange beträgt 30 Sekunden und im Durchschnitt sind 11 Kunden in der Warteschleife vorhanden (*Average Queue*).

Entscheidend ist nun die „*Utilisation*“, also die Auslastung der Operatoren. Bei 30 Agenten würde diese 94% betragen, das heißt im betrachteten Zeitintervall (hier eine Stunde) würde der Anteil der Zeit, in der der Operator auf einen Anruf wartet, 6% betragen. Wird nun die Zeile mit nur 29 Agenten betrachtet, so wird deutlich, dass zum einen der Servicelevel auf 56/20 fällt, während die Agentenauslastung auf 98% ansteigt. Im Vergleich dazu würde eine Operatorenanzahl von 31 einen Servicelevel von 96/20 ermöglichen, wobei hier die Auslastung der Mitarbeiter bei 91% liegen würde. Dies lässt den Schluss zu, dass bei einer hohen Agentenauslastung der Servicelevel überproportional fällt.

Fraglich ist nun, was die „optimale“ Auslastung wäre. Auf den ersten Blick erscheint eine 100%ige Auslastung als erstrebenswert, zumal hierbei keiner der Mitarbeiter untätig rum sitzen würde. Allerdings kann in der Praxis ein derart hoher Wert nicht aufrechterhalten werden. Vielmehr hat sich hier eine Auslastung von etwa 80%²⁶ als guter Wert erwiesen, denn zum einen sind bei einer höheren Belastung die Agenten gestresst, was sich auf die Kundenfreundlichkeit auswirkt und demnach wiederum auf das Image des Call Centers zurückfällt. Zum anderen besteht die Gefahr von sehr hohen Auslastungsgraden, dass ein plötzlich aufkommender Call-Peak, der so nicht eingeplant war, sehr schnell zu einer kompletten Überforderung des Call Centers führen kann und damit das Servicelevel drastisch nach unten abfällt. Derartige Spitzenbelastungen sollten nur für kurze Zeit bestehen und nicht ein Dauerzustand sein.

²⁶ Vgl. Menzler-Trott (1999), S. 335.

2.4 Die Mitarbeiterstruktur in Call Centern

Die wohl wichtigste Komponente im Call Center ist der Mensch selbst. Zum einen deswegen, da er mit über 70% den größten Kostenfaktor im Call Center darstellt²⁷ und zum anderen steht und fällt mit ihm die Servicequalität und damit auch das Bild, das das Unternehmen nach außen vermittelt. An die Agenten werden oft sehr hohe Anforderungen gestellt. Hierunter sind derartige Grundvoraussetzungen, wie hohe Stress- und Frustrationstoleranz, wie auch ein positives Menschenbild geknüpft. Ihre Fähigkeit zur Selbstmotivation ist ebenso entscheidend, wie eine stets kompetente und freundliche Ausstrahlung über das Telefon. Gerade im Inbound Call Center ist auch ein ausgeprägtes Servicebewusstsein von großer Bedeutung, die dann oft in Sympathie und Vertrauen seitens der Kunden mündet.²⁸ Hierin liegt wiederum die Basis für eine lang anhaltende Kundenbindung.²⁹

Eng damit verbunden ist auch die Qualifikation des entsprechenden Agenten zur Bearbeitung der unterschiedlichen Anruftypen. Grundsätzlich können in einem Call Center folgende Anrufprofile und damit auch Qualifikationsstufen unterschieden werden:³⁰ Im Wesentlichen existieren drei verschiedene Qualifikationsstufen, die mit Q1, Q2 und Q3 unterschieden werden. Unter Q3 werden dabei jene Operatoren zusammengefasst, die sämtliche Anrufe aus dem nationalen Telefonnetz entgegennehmen und bearbeiten. Es stellt gleichzeitig die niedrigste Stufe dar. Auf das Qualitätsniveau Q2 entfallen Agenten, die in erster Linie die Business Customer, die einen Exklusivvertrag mit dem Call Center abgeschlossen und damit Sonderkonditionen und auch Sonderleistungen haben, bedienen. Operatoren in Q2 werden auch zur Bewältigung der Anrufe aus dem nationalen Netz herangezogen, sofern es ihre Auslastung zulässt. Schließlich befinden sich auf der höchsten Stufe Q1 jene Agenten, die in erster Linie internationale Anfragen beantworten. Dies erfordert insbesondere umfangreiche Fremdsprachenkenntnisse, die auch als Qualifikationsmerkmal ausschlaggebend sind. Sofern es auch hier das Anrufaufkommen zulässt, können diese Agenten auch Businesskunden und nationale

²⁷ Vgl. Böse/Flieger (1999), S. 43

²⁸ Vgl. Wiencke/Koke (1999), S.101f.

²⁹ Vgl. Böse/Flieger (1999), S. 49f.

³⁰ Vgl. Infoportal, interne Angaben.

Anrufe übernehmen. Diese Art der Untergliederung der Mitarbeiter ist vor allem im Bereich des *skilled-based Routing* von großer Bedeutung. In vielen Call Centern ist eine bedarfsorientierte Schichtgruppeneinteilung ein wesentlicher Grundbaustein der Personalplanung. Folgende Grafik zeigt nochmals die Einteilung der Qualifikationsstufen nach dem Calltyp auf:

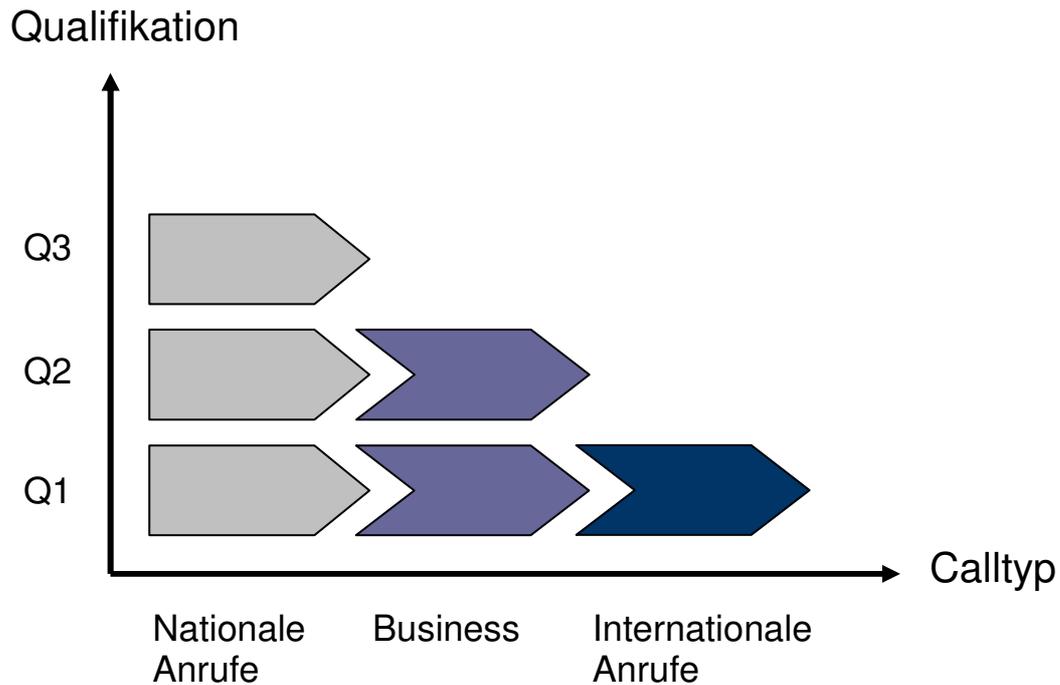


Abbildung 2.6: Qualifikationsprofil von Agenten

Für die Einteilung der Agenten in eine der drei Qualifikationsstufen werden die Agenten einer regelmäßigen Bewertung durch die Vorgesetzten unterzogen. Hierbei müssen die Mitarbeiter Testanrufe absolvieren und auf deren Basis werden sie dann hinsichtlich Arbeitsmethodik, Arbeitsergebnis, Gesprächsführung und einigen anderen Kennzahlen bewertet. Als Arbeitsergebnis zählt dabei unter anderem, ob die richtige Information an den Anrufer weitergegeben oder ob eine korrekte Weiterverbindung eingeleitet wurde. Unter die statistischen Kennzahlen fallen Größen, wie die gemessene Gesprächszeit (je kürzer die Call-Abwicklung ist, umso

höher ist die Punktezahl der Bewertung) oder die Call Completion Rate³¹. Die Summe der vergebenen Punkte bildet dann wiederum die Grundlage für die Einteilung eines Agenten in eine der drei Qualifikationsstufen. Zudem dienen sie auch als Indikator für eine Nachschulung oder für Weiterbildungsmaßnahmen.

In der vorliegenden Arbeit wird diese Unterscheidung im Qualifikationsprofil nicht getroffen, d. h. es wird im Folgenden von einer homogenen Agentenstruktur ausgegangen und auf dieser Prämisse werden die entsprechenden Analysen in Kapitel 6 durchgeführt.

2.5 Die Wahl der richtigen Rufnummer

Ein wichtiges Thema für jedes Call Center ist auch die Entscheidung, welche Rufnummer gewählt werden soll, unter der das Call Center erreichbar ist.

Hierzu empfiehlt sich eine möglichst einprägsame Ziffernfolge, die durch Werbemaßnahmen sehr gut vermarktbar und kommunizierbar ist und zudem eine möglichst gute Abgrenzung zu Konkurrenten erlaubt. Häufig wird hierzu auch eine sog. „Vanity-Number“³² geschaltet. Sie stellt eine Buchstaben-Rufnummer dar, wobei ein bestimmter Name ausgewählt wird – meistens der Firmenname – unter der das Unternehmen erreichbar ist. Der Name wiederum kann dann in eine Telefonnummer übersetzt werden, indem die entsprechende alphanumerische Tastenkombination eingegeben wird. Derartige Buchstabennummern können gemäß der Bundesnetzagentur für Elektrizität, Gas, Telekommunikation, Post und Eisenbahn für Mehrwertdienste beantragt werden.

Ein wichtiger Punkt in der Wahl der richtigen Rufnummer ist auch, wer die Kosten trägt und wie groß diese sind. Kostenfreie oder zumindest kostengünstige Rufnummern für die Anrufer sind äußerst kundenfreundlich und genießen ein höheres Ansehen. Allerdings ist damit auch immer die Gefahr von sog. „Junk-Calls“

³¹ Call Completion Rate ist das Verhältnis aus erfolgreich abgeschlossenen Gesprächen zu der Gesamtzahl der von der ACD-Anlage registrierten Anrufversuchen. Dabei zählen auch Telefonate, die vom Anrufer vor der Entgegennahme abgebrochen wurden. Vgl. hierzu Bodin/Dawson (2002), S. 40.

³² Vgl. hierzu und im Folgenden Thieme/Steffen (1999), S. 84.

gegeben. Kostenlose Rufnummern ziehen nämlich insbesondere Spaßanrufe auf sich, was für die Kostenbelastung eines Call Centers oft nicht unerheblich ist.

Grundsätzlich sind kostenlose Rufnummern charakterisiert durch die Vorwahl 0800 oder 00800, für den Kunden kostenreduzierte Anrufe sind gekennzeichnet durch die Gebührenvarianten der 0180er Nummern. Die oft in Verruf geratene Gasse 0190 steht seit Anfang 2006 nicht mehr zur Verfügung und wurde abgeschaltet. Bis Mitte des Jahres 2006 dürfen hier noch kostenfreie Ansagen laufen mit dem Hinweis, dass sich die Rufnummer geändert hat. An ihre Stelle tritt nun die Servicenummer 0900, wobei diese nun den Vorteil hat, dass Anrufer bei der Bundesnetzagentur nachfragen können, wer hinter dieser Mehrwertnummer steckt.³³ Allerdings ist anhand dieser neuen Nummer nicht mehr eindeutig erkennbar, wie viel der Anruf kosten wird. Bei den 0190er Nummern war dies möglich, da die erste Ziffer nach der 0190 jeweils für einen bestimmten Preis stand.

³³ Vgl. hierzu „Gesetz zur Bekämpfung des Missbrauchs von 0190er-/090er-Mehrwertnummern“ Art.1

Kapitel 3: Grundlagen künstlicher neuronaler Netze

Nach der einführenden Darstellung der wichtigsten Call Center-Begriffe, wird nun im Folgenden das theoretische Konzept künstlich neuronaler Netze zur Prognose des Callvolumens dargestellt.

Neuronale Netze haben in den verschiedensten Bereichen ihren Eingang gefunden und sind für Klassifizierungs- und Prognosezwecke nicht mehr wegzudenken.

Aufgrund der Komplexität der Thematik und der starken Anlehnung an das biologische Vorbild sollen in diesem Kapitel zum einen kurz die neurophysiologischen Grundlagen und zum anderen auch der Aufbau und die Bestandteile von künstlichen neuronalen Netzen dargestellt werden. Im weiteren Verlauf des Kapitels wird speziell die Theorie der Perzeptrone ausführlicher erläutert, zumal dieser Netztyp aufgrund seiner besonderen Eigenschaften gerade für Prognosezwecke sehr geeignet ist und deshalb für die Vorhersage des Callvolumens in Kapitel 4 verwendet wird.

3.1 Das biologische Vorbild

Informationen aufzunehmen und zueinander in Beziehung zu setzen ist eine der wichtigsten Fähigkeiten des menschlichen Gehirns und zeichnet den Menschen aus. Eben diese außerordentliche Fähigkeit war letztlich auch in den 40er Jahren der Grund für die Überlegung von *Warren McCulloch* und *Walter Pitts*³⁴ oder auch *Norbert Wiener* und *John von Neumann*³⁵, die in entsprechenden Artikeln und Büchern die Empfehlung aussprachen, den Fokus vermehrt auf die Entwicklung von Modellen zu legen, die nach dem Vorbild des menschlichen Gehirns agieren sollen.

Der grundlegende Ablauf der Informationsverarbeitung im menschlichen Gehirn ist dabei folgender:

Informationen werden in Form von elektrochemischen Reizen über spezielle Leitungen, den *Dendriten*, an das Neuron herangetragen und über *Synapsen* an das

³⁴ Vgl. McCulloch/Pitts (1943).

³⁵ Vgl. von Neumann (1951).

Neuron übergeben. Entscheidend ist, dass die Synapsen als Bindeglied zwischen Dendriten und Zellkörper stehen und zudem den übermittelten Reiz zusätzlich hemmen („*inhibitorische Synapse*“) oder verstärken („*exzitatorische Synapse*“) können³⁶. Ist der ankommende Reiz so stark, dass die elektrische Spannung im Neuron einen bestimmten Schwellenwert überschreitet, so gilt die Zelle als aktiviert und sie feuert. Allgemein wird der Erregungszustand eines Neurons als *Aktionspotential* bezeichnet.³⁷ Im weiteren Verlauf gibt nun die Nervenzelle ihrerseits elektrochemische Impulse über das sog. *Axon*, das auch als Ausgabeleitung angesehen werden kann, an nach geschaltete Neuronen ab. Entscheidend ist, dass ein Neuron mehrere Tausend Synapsen an den Eingangs- und Ausgangsströmen hat und demnach eine sehr hohe Konnektivität zwischen den Nervenzellen besteht. Die Informationsweitergabe und -verarbeitung kann somit in einer extrem hohen Geschwindigkeit von statten gehen. Weiterhin ist von großer Bedeutung, dass die Informationsverarbeitung *parallel*, also voneinander unabhängig und damit gleichzeitig erfolgt.

Die Bedeutung der Synapsen ist aus zweierlei Gründen so groß: Zum einen können sie eingehende Reize verstärken oder hemmen und zum anderen können sie ihre Wirkung im Zeitablauf ändern. Dies ist insbesondere entscheidend, da hierin die Fähigkeit des Lernens von Neuronen begründet liegt. Je nachdem, wie oft eine Synapse benutzt wird, kann sie wachsen, verkümmern oder sogar ganz verschwinden, aber auch neue Verbindungen können gebildet werden.³⁸

Diese Grundtugenden natürlicher neuronaler Netze, wie die *Lernfähigkeit*, die *parallele Verarbeitung* von Informationen, die *Einfachheit* der strukturellen Gestaltung, der *gerichtete Informationsfluss* zwischen den Nervenzellen über die Synapsen und die relativ hohe *Konnektivität* der Neuronen wurden versucht, in die Modellierung der künstlichen neuronalen Netzen zu implementieren. Allerdings sind dem auch Grenzen gesetzt, so dass eine Vielzahl an Eigenschaften des biologischen Vorbildes nicht adäquat abgebildet werden kann. Hierzu ist unter anderem die reduzierte Anzahl an Neuronen zu nennen, die aus Komplexitätsgründen eine Begrenzung erfährt und damit auch eine reduzierte Anzahl an Verbindungen zur

³⁶ Vgl. Kinnebrock (1994), S. 15.

³⁷ Vgl. Hoffmann (1993), S. 2.

³⁸ Vgl. Hoffmann (1993), S. 1.

Folge hat, oder die zum Teil in der Biologie noch völlig unerforschten Lernregeln, die meistens aus mathematischen oder physikalischen Modellen abgeleitet wurden, um eine technische Anwendung zu ermöglichen.³⁹

Im Folgenden sollen nun die technischen Umsetzungen der biologischen Nervenzellen in einem statistisch-mathematischen Kontext näher erläutert werden.

3.2 Ein einfaches Modell künstlicher neuronaler Netze

Rumelhart stellt für den formalen Aufbau von künstlichen neuronalen Netzen folgende Komponenten auf:⁴⁰

- Verarbeitungseinheiten („*units*“, *Neuronen*)
- Aktivierungspotential
- Outputfunktion für jede Unit
- Verbindungen zwischen den Units („*weights*“)
- eine Regel der Signalverarbeitung („*rule of propagation*“)
- eine Funktion zur Bildung des Aktivierungswertes einer Unit („*activation function*“)
- eine Lernregel („*learning rule*“) und
- eine entsprechende Umgebung, in der das System arbeitet („*environment*“).

3.2.1 Das Neuron als kleinste Einheit im System

Die kleinste Einheit in einem künstlichen neuronalen Netz stellt das *Neuron* dar und ist zudem neben den Verbindungen untereinander Hauptbestandteil der Topologie. Das Neuron repräsentiert, ebenso wie das biologische Vorbild, die Verarbeitungseinheit der eingehenden Informationen und sorgt letztendlich für einen bestimmten Output an Information. Je nach Anzahl und Anordnung der Units und ihrer Verbindungen kann die Netzwerktopologie charakterisiert werden. Sei n_j das

³⁹ Vgl. Zell (2000), S. 52f.

⁴⁰ Vgl. hierzu und im Folgenden Rumelhart (1986), S. 46-49.

j -te Neuron in einem Netzwerk, so ergibt sich die Ausgabeinformation o_j , indem zunächst aus den ankommenden Signalen und den entsprechenden Gewichten w_{ij} der Nettoinput net_j berechnet wird. Daraus wird dann über die Aktivierungsfunktion der Grad der Aktivierung a_j bestimmt und diese wiederum legt schließlich über die Outputfunktion die Höhe des Ausgangssignals o_j fest.

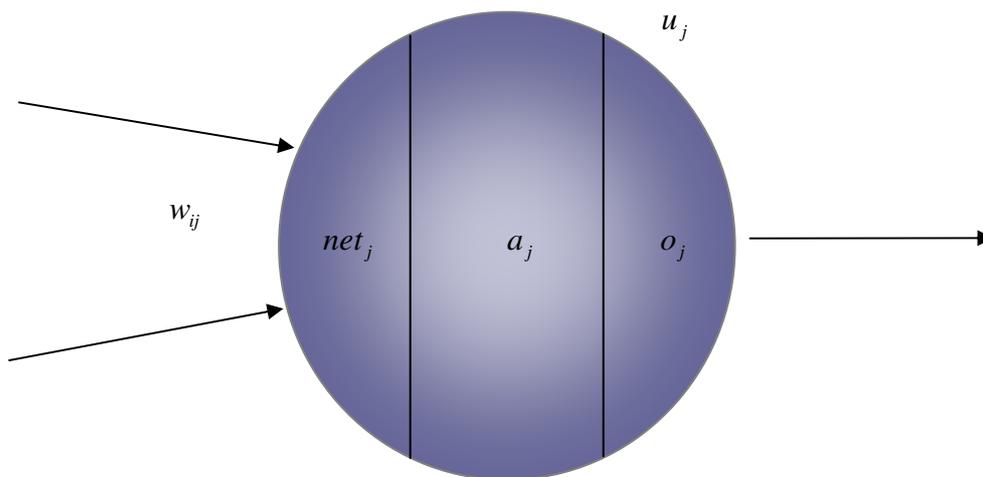


Abbildung 3.1: Formaler Aufbau eines Neurons

Je nach Position der Units im Netzwerk können folgende Typen unterschieden werden:⁴¹

- *Eingabeneuron* („input units“): Sie repräsentieren jene Einheiten, in denen die Eingabeinformationen für das gesamte Netz enthalten sind. Im mathematischen Sinn handelt es sich hier um jene Neuronen, die die unabhängigen Variablen im Analysesystem bestimmen.
- *Verdeckte Neuronen* („hidden units“)⁴²: Diese Units werden deshalb als verdeckt bezeichnet, da ihre „Ausgänge von außen nicht zugänglich sind“⁴³.

⁴¹ Vgl. hierzu und im Folgenden, Zell (2000), S. 73f.

⁴² Zu den Hidden-Units ist anzumerken, dass sie einen Spezialfall darstellen und nur in den Multi-Layer Topologien vorkommen können. Dieser Spezialtyp von künstlichen neuronalen Netzen wird noch ausführlicher in den nachfolgenden Kapiteln dargestellt.

⁴³ Vgl. Hoffmann (1993), S. 39.

Sie haben grundsätzlich Verarbeitungs- und Verteilungsfunktion und werden aus diesem Grund auch oft mit „*Interne Repräsentation*“⁴⁴ titulierte.

- *Ausgabeneuronen* („*output units*“): Hier werden die Zielwerte des mathematischen Modells ausgegeben.

Wie bereits angesprochen, sind neben den einzelnen Units auch die Verbindungen im künstlichen neuronalen Netz entscheidend, zumal beide Komponenten zusammengefasst die *Netzwerktopologie* eindeutig bestimmen.

3.2.2 Verbindungen und Netzwerktopologie

Analog zu den Synapsen im biologischen Vorbild sind auch im künstlichen Modell die einzelnen Units miteinander verbunden und können so miteinander kommunizieren. Jeder Verbindung wird dabei eine reelle Zahl zugeordnet, die als *Gewichtung* („*weight*“⁴⁵) bezeichnet wird. Die Gewichte w_{ij} zwischen dem sendenden Neuron i und dem empfangenden Neuron j bestimmen letztendlich auch die Lernfähigkeit des Netzwerkes⁴⁶, zumal sie die veränderbaren Größen im Trainingsprozess repräsentieren, die jeweils eine Anpassung erfahren, um eine optimale Netzadaption zu erzielen. Wie diese Lernprozesse im Einzelnen ausgestaltet sind, wird in Kapitel 3.4.3 noch genauer dargestellt.

Üblicherweise wird bei der Darstellung des Verbindungsmusters innerhalb eines Netzes die Matrizennotation verwendet, so dass die Verbindungsstruktur eines künstlichen neuronalen Netzes mit N Units auch folgendermaßen formal darstellbar ist:⁴⁷

⁴⁴ Vgl. Brause (1995), S. 240.

⁴⁵ Vgl. Rumelhart (1986), S. 49.

⁴⁶ In der Literatur wird in diesem Zusammenhang auch zum Teil genau die umgekehrte Bedeutung von w_{ij} angetroffen, d.h. dies würde dann einer Verbindung von Neuron j zu Neuron i entsprechen.

⁴⁷ Vgl. Zell (2000), S. 75.

$$\underline{W} = \begin{bmatrix} w_{11} & w_{12} & \Lambda & w_{1N} \\ w_{21} & w_{22} & \Lambda & w_{2N} \\ \mathbf{M} & \mathbf{M} & \mathbf{O} & \mathbf{M} \\ w_{N1} & w_{N2} & \Lambda & w_{NN} \end{bmatrix}.$$

Wie bereits erwähnt, bilden das Vorzeichen und der Absolutbetrag der w_{ij} die Wirkungsrichtung und die Intensität der Verbindungen ab. Hierbei ist zu unterscheiden zwischen:⁴⁸

- $w_{ij} = 0$, es besteht keine Verbindung zwischen Unit i und Unit j ,
- $w_{ij} < 0$, Unit i hat einen hemmenden Einfluss auf Unit j ,
- $w_{ij} > 0$, Unit i hat einen anregenden Einfluss auf Unit j .

Die Initialisierung der Gewichte erfolgt mit zufälligen Werten, die dann schrittweise während des Lernprozesses solange adaptiert werden, bis ein gewünschtes Verhalten des Netzes erreicht ist.

Neben der Wirkung der Gewichte, ist auch der Informationsfluss von entscheidender Bedeutung, da er zusammen mit dem hierarchischen Aufbau des Netzes, den Typ der Netzwerkkonstruktion bestimmt.⁴⁹ Je nachdem, ob die Neuronen in Schichten organisiert sind, können „einschichtige“ und „geschichtete Netzwerke“⁵⁰ unterschieden werden.

In *hierarchischen* Systemen sind die Units in *Schichten* („Lagen“, „Layers“, „Ebenen“)⁵¹ organisiert und die einzelnen Units sind jeweils nur mit Units aus den unmittelbar benachbarten Schichten verbunden. Bei den sog. „*Feedforward Netzen*“⁵² werden dabei die einzelnen Elemente einer Schicht nur von Elementen einer untergeordneten Lage beeinflusst und sie selber können ihre Information auch jeweils nur an Elemente einer höheren Ebene abgeben. Der Informationsfluss ist in diesen Systemen also nur in einer Richtung möglich. Übertragen auf die

⁴⁸ Vgl. Rumelhart (1986), S. 49f.

⁴⁹ Vgl. hierzu und im Folgenden, Karayiannis (1993), S. 9f.

⁵⁰ Grauel (1992), S. 33f.

⁵¹ Vgl. Hoffmann (1993), S. 39.

⁵² Vgl. Rigoll (1993), S. 46f.

Gewichtungsmatrix würde dies bedeuten, dass \underline{W} eine obere Dreiecksmatrix darstellt.

In *nicht hierarchischen* Systemen sind dementsprechend die Units nicht in Schichten eingeteilt und es besteht daher auch keine Ordnung mehr. Jedes Element kann mit jedem anderen beliebig in Verbindung treten. Dabei sind auch *Rekursionen* möglich, d. h. ein Neuron kann auch mit sich selbst verbunden sein und damit wird sein Ausgangssignal wiederum ein eigenes Eingangssignal.⁵³ Häufig werden derartige Netztypen auch als „*Feed-back*“⁵⁴ Netzwerke genannt. Der bekannteste Vertreter derartiger künstlicher neuronaler Netze ist das *Hopfield-Modell*, das hauptsächlich bei Optimierungsproblemen (Traveling Salesman Problem)⁵⁵ aber auch zur Mustererkennung⁵⁶ eingesetzt wird.

In der vorliegenden Arbeit wird allerdings der Typus der Feedforward-Netze die zentrale Rolle spielen, da sich insbesondere die sog. Multi-Layer-Perzeptrene besonders für Prognosezwecke eignen.

3.3 Funktionale Zusammenhänge

3.3.1 Die Propagierungsfunktion

Die *Propagierungsfunktion* („rule of propagation“⁵⁷), die auch häufig als „Eingangsfunktion“⁵⁸ bezeichnet wird, legt nun fest, wie die ankommenden Informationen in einem Neuron gebündelt werden und damit den Nettoinput net_j bilden. Bezeichnet x_i nun zudem die Eingänge⁵⁹ in ein Neuron, so sind grundsätzlich folgende Methoden zu unterscheiden:

⁵³ Vgl. Gurney (1997), S. 98.

⁵⁴ Vgl. Karayiannis (1993), S.46.

⁵⁵ Vgl. Rojas (1993), S. 308-310. und Nauck (1996), S. 147-149.

⁵⁶ Vgl. Nauck (1996), S. 144-146.

⁵⁷ Vgl. Rumelhart (1986), S. 51.

⁵⁸ Vgl. Hoffmann (1993), S. 15.

⁵⁹ Diese Eingänge sind gleichzusetzen mit den jeweiligen Outputs von vorausgegangenen Neuronen.

- Summation der gewichteten Eingabe:

$$net_j = \sum_{i=1}^n w_{ij} x_i ;$$

- Maximalwert der gewichteten Eingabe:

$$net_j = \max(w_{ij} x_i) ;$$

- Produkt der gewichteten Eingabe:

$$net_j = \prod_{i=1}^n w_{ij} x_i ;$$

- Minimalwert der gewichteten Eingabe:

$$net_j = \min(w_{ij} x_i) .$$

In der Literatur ist es häufig so, dass die gewichtete Summe der Eingänge als Netto-Input gewählt wird.⁶⁰ Ein wesentlicher Vorteil dieser Funktion liegt darin, dass einerseits tatsächlich alle Reize in die Berechnung eingehen und zum anderen die Funktion nicht den Wert Null annimmt, wenn nur eine Eingabe den Wert Null aufweist, d. h. es handelt sich um ein kompensatorisches Modell, wobei keine Mussfaktoren vorzuliegen haben.

Die obigen Ausführungen beziehen sich alle auf einen fixen Zustandszeitpunkt t , weshalb die Zeitkomponente in der Darstellung außer Acht gelassen wurde. Nun ist aber zu beachten, dass während der Trainingsphase ein künstliches neuronales Netz mehrere Anpassungsdurchläufe erlebt, so dass sich die Netzeingaben für ein und dasselbe Neuron im Zeitablauf ändern. Um diesen Sachverhalt auch formal abbilden zu können, ist der Faktor t zu berücksichtigen. Somit lautet die Formel für den Nettoinput auch vollständigerweise:

$$net_j(t) = f(x_i(t), w_{ij}) .$$

Die übrigen Einflussparameter wie Aktivierungszustand und Output sind analog mit dem Zeitfaktor zu versehen.

⁶⁰ Vgl. Rumelhart (1986), S. 71; Zell (2000), S. 74 und Grauel (1992), S. 29.

3.3.2 Die Aktivierungsfunktion

Der Aktivierungszustand $a_j(t)$ des Neurons j zum Zeitpunkt t wird über eine sog. *Aktivierungsfunktion* f_{act} bestimmt.⁶¹ Die Transferfunktion berechnet dabei allgemein den aktuellen Aktivierungszustand $a_j(t)$ aus dem Aktivierungszustand zum vorherigen Zeitpunkt $a_j(t-1)$ und dem momentan vorhandenen Nettoinput net_j :

$$a_j(t) = f_{act}(a_j(t-1), net_j(t)).$$

Allerdings ist es in vielen Fällen so, dass die Neuronen „kein Gedächtnis“⁶² haben, d. h. der Vorzustand der Verarbeitungseinheit $a_j(t-1)$ geht nicht in die Berechnung des Aktuellen ($a_j(t)$) ein, so dass eigentlich gilt:

$$a_j(t) = f_{act}(net_j(t)).$$

Es existieren auch hier unterschiedliche Arten von Aktivierungsfunktionen. Eine Grobeinteilung kann durch die beiden Begriffe *diskret* („discrete“) und *stetig* („continuous“) erfolgen.⁶³ Im Falle stetiger Funktionen kann wiederum eine Unterscheidung getroffen werden, ob alle reellen Zahlen angenommen werden können, oder ob der Wertebereich auf ein Intervall beschränkt ist. Häufig ist es so, dass bei kontinuierlichen Funktionen ein Intervall vorgegeben ist (meistens $[0,1]$ oder $[-1,1]$), innerhalb dessen die entsprechende Aktivierungsfunktion einen Wert annehmen kann.

Im Fall diskreter Aktivierungsfunktionen sind die Werte meistens binär, wobei häufig die Ausprägungen 0 und 1 angenommen werden. Null bedeutet, dass die Zelle inaktiv und Eins, dass sie aktiviert ist und damit auch feuert. Anderenorts kann die

⁶¹ Vgl. Rumelhart (1986), S. 52.

⁶² Vgl. Zell (2000), S. 83.

⁶³ Vgl. hierzu und im Folgenden Rumelhart (1986), S. 48.

binäre Ausprägung auch auf $[-1,1]$ oder einfach $[-,+]$ begrenzt sein. Zudem ist noch die Möglichkeit gegeben, eine bestimmte Werteausprägung im diskreten Bereich zuzulassen, wie etwa alle ganzzahligen Werte eines bestimmten Intervalls. Einen kurzen Überblick hierzu findet sich in untenstehender Abbildung:

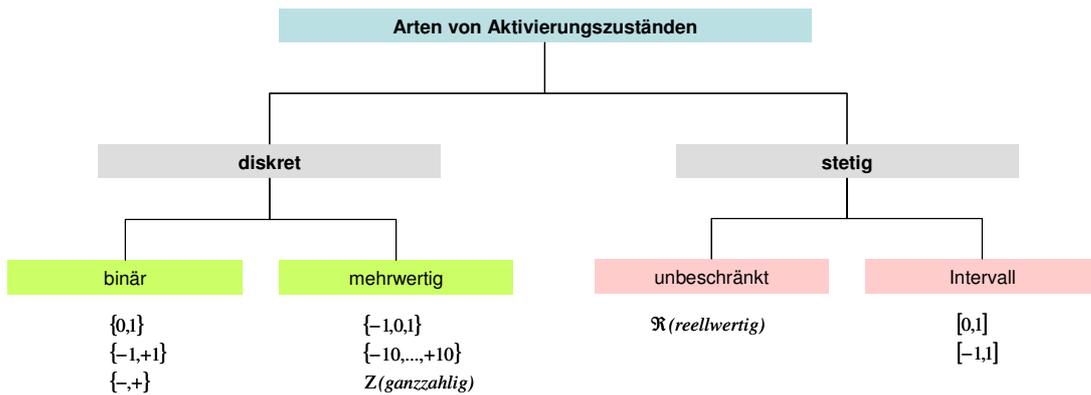


Abbildung 3.2: Überblick über die möglichen Aktivierungszustände

Die eben beschriebenen Aktivierungszustände eines Neurons können mit unterschiedlichen Aktivierungsfunktionen erreicht werden. Die üblichsten Formen sind hierbei die *lineare Funktion*, die *Schwellenwertfunktion* oder die *Sigmoidfunktion*.

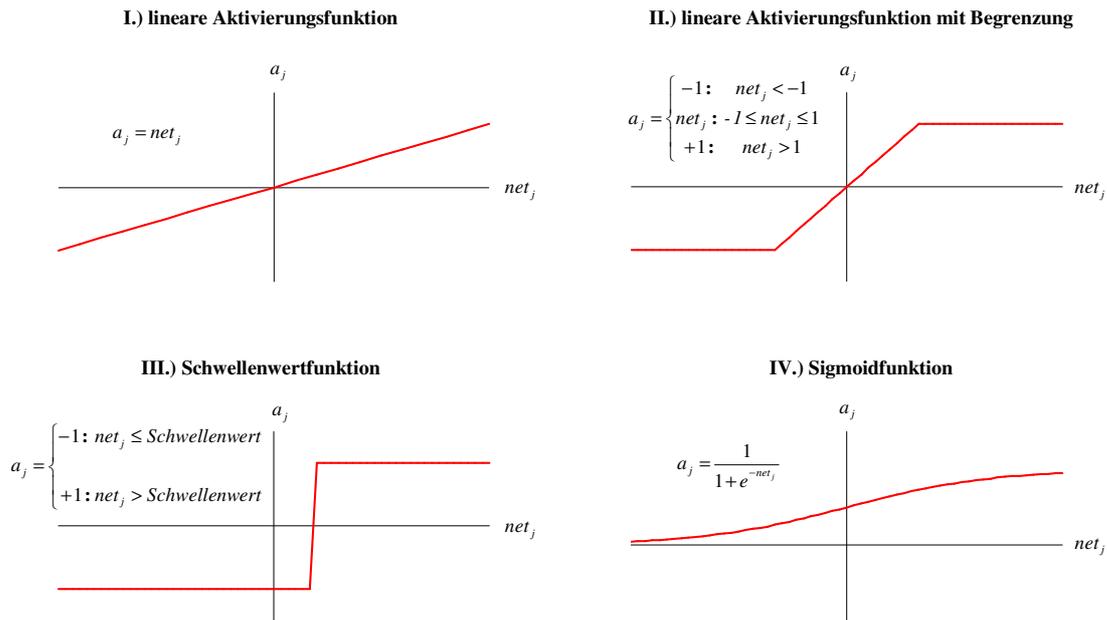


Abbildung 3.3: Überblick über die grundlegenden Aktivierungsfunktionen

Die in diesem Zusammenhang geforderte Annahme, dass die Aktivierungsfunktion mit zunehmendem Nettoinput auch ansteigt, also monoton steigend ist⁶⁴, wird durch alle oben aufgeführten Funktionen erfüllt, so auch die lineare Funktion, allerdings würde ihre Anwendung den großen Vorteil der künstlich neuronaler Netze, nämlich die Implementierung nichtlinearer Zusammenhänge abzubilden, ausschalten. Der Grund hierfür liegt darin, dass sich mehrere hintereinander geschaltete Neuronen mit einer linearen Aktivierungsfunktion letztlich wieder zu einer einzigen linearen Funktion zusammenschließen lassen und daher das gesamte Netzwerk auf ein einlagiges künstliches neuronales Netz reduzierbar wäre.⁶⁵ Dies führt in der Praxis auch häufig dazu, dass lineare Aktivierungsfunktionen weniger häufig verwendet werden. Zudem ergibt sich das Problem, dass der Nettoinput durch diese lineare Transformation praktisch keine Klassifizierung erfährt⁶⁶ und es daher gerade bei großen und kleinen Ausprägungen des Nettoinputs günstiger sein kann, wenn der resultierende Aktivierungswert auf ein Intervall beschränkt wird. In diesem Fall

⁶⁴ Vgl. Hoffmann (1993), S. 21.

⁶⁵ Vgl. Lippmann (1987), S. 15.

⁶⁶ Vgl. Kratzer (1993), S.25.

würde sich dann eine lineare Aktivierungsfunktion mit Begrenzung, wie in Abbildung 3.3(II) dargestellt, empfehlen.

Auch die binäre Schwellenwertfunktion (siehe Abbildung 3.3(III)) stellt eine sehr einfach zu berechnende Aktivierungsfunktion dar. In diesem Fall nimmt $a_i(t)$ den Wert „-1“ an, wenn die Gesamteingabe in das Neuron einen bestimmten Schwellenwert nicht erreicht, ansonsten, wenn er überschritten wird, erlangt das Neuron den Aktivierungszustand von „1“. Der einfachen Berechnung steht allerdings der gravierende Nachteil der Nicht-Stetigkeit und Nicht-Differenzierbarkeit gegenüber. Die Konsequenz hierbei ist, dass der Gebrauch der Differentialrechnung in der Netzwerkoptimierung stark eingeschränkt ist.⁶⁷ In der Literatur wird daher auch an die Aktivierungsfunktion stets die Bedingung der Stetigkeit und Differenzierbarkeit geknüpft.⁶⁸

Aus diesem Grund werden diese Funktionen auch oft durch *sigmoide Funktionen*, wie in Abbildung 3.3(VI) aufgezeigt, ersetzt. Die häufig benutzten Sigmoidfunktionen sind die *logistische Funktion* und der *Tangens Hyperbolicus*.⁶⁹

Beide Funktionen werden nun etwas ausführlicher dargestellt, da sie die am häufigsten verwendeten Funktionen in Verbindung mit den in Kapitel 3.4.3.3 beschriebenen MLPs sind.

Die logistische Funktion lässt sich formelmäßig darstellen als:

$$f_{act}(net_j) = \frac{1}{1 + e^{-net_j}}.$$

Ihre Ableitung lautet:⁷⁰

$$f'_{act}(net_j) = f_{act}(net_j)(1 - f_{act}(net_j)).$$

⁶⁷ Vor allem in künstlichen neuronalen Netzen, die den Backpropagation-Algorithmus, der in Kapitel 3.4.3.3 noch ausführlich dargestellt wird, als Optimierungsmodell anwenden, muss eine stetige und differenzierbare Aktivierungsfunktion vorliegen.

⁶⁸ Vgl. Rumelhart (1986), S. 52.

⁶⁹ Vgl. hierzu und im Folgenden Zell (2000), S. 90-93.

⁷⁰ Die Ableitung wird bereits hier der Vollständigkeit halber aufgeführt, da sie später noch eine gewichtige Rolle spielen wird.

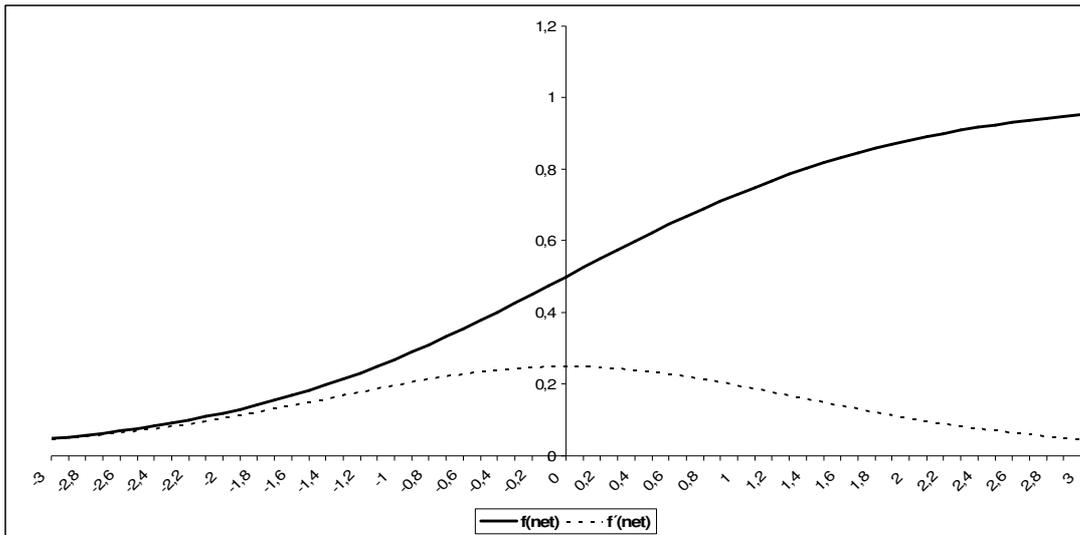


Abbildung 3.4: Logistische Funktion

Der Tangens Hyperbolicus hingegen hat formal und grafisch folgende Gestalt:

$$f_{act}(net_j) = \tanh(net_j) = \frac{e^{net_j} - e^{-net_j}}{e^{net_j} + e^{-net_j}}$$

und

$$f'_{act}(net_j) = 1 - (f_{act}(net_j))^2.$$

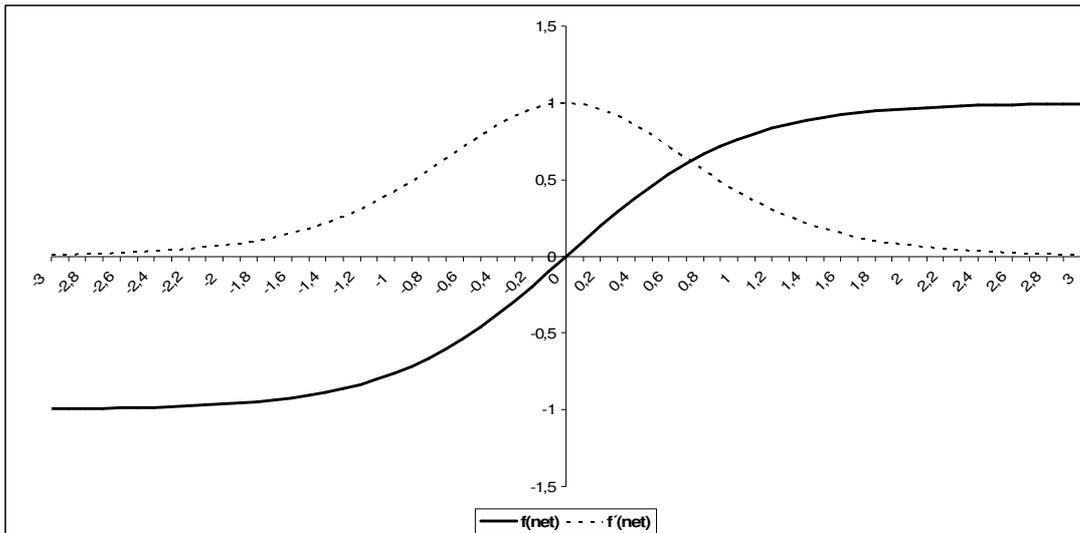


Abbildung 3.5: Tangens Hyperbolicus Funktion

Beide Funktionen sind stetig und differenzierbar. Der Unterschied liegt hauptsächlich im Wertebereich. Während die logistische Funktion auf den Bereich $]0,+1[$ variiert, liegt er bei der Tangens Hyperbolicus Funktion im Intervall $]-1,+1[$.⁷¹

3.3.3 Die Outputfunktion

Die Outputfunktion f_{out} hat die Aufgabe, in Abhängigkeit vom aktuellen Aktivierungszustand $a_j(t)$ den Ausgabewert $o_j(t)$, der dann wiederum an die nach gelagerten Neuronen weitergeleitet wird und dort als Eingabewert $x_j(t)$ dient, zu bestimmen:

$$o_j(t) = f_{out}(a_j(t)).$$

Auch hier sind grundsätzlich wieder alle Funktionen wie im vorherigen Kapitel denkbar, wobei die Gültigkeit von Stetigkeit und Differenzierbarkeit wieder Bestand

⁷¹ Die Bedeutung und Auswirkung der unterschiedlichen Wertebereiche wird in Kapitel 3.4.3.3.2 noch näher erläutert.

haben muss.⁷² Meistens wird hierbei allerdings die sog. „Identitätsfunktion“⁷³ angewendet, d. h. der Ausgabewert $o_j(t)$ entspricht dem aktuellen Aktivierungszustand $a_j(t)$.

In diesem Zusammenhang ist auch noch anzumerken, dass in der Literatur nicht immer exakt zwischen Input-, Aktivierungs- und Outputfunktion unterschieden wird. Aufgrund der Identitätsfunktion als Ausgabefunktion werden die Aktivierungs- und die Outputfunktion auch sehr oft zusammengefasst und als *Transferfunktion* f_{trans} bezeichnet.⁷⁴

Unten stehende Grafik zeigt nochmals in einer Gesamtübersicht das Zusammenspiel der funktionalen Größen in einem Neuron.

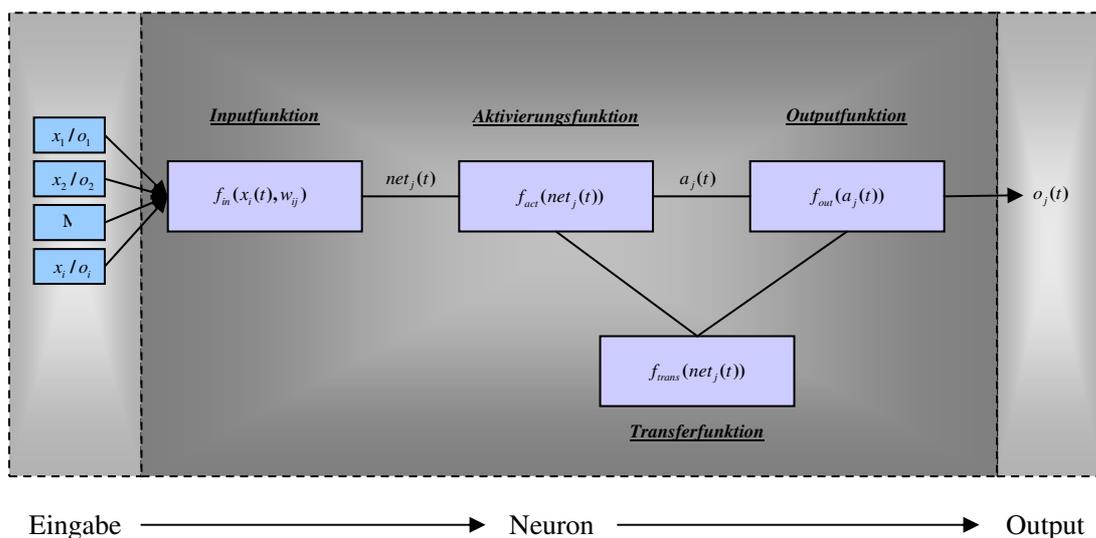


Abbildung 3.6: Zusammenfassung der funktionalen Zusammenhänge in einem Neuron

⁷² Vgl. Hoffmann (1993), S. 21.

⁷³ Vgl. Zell (2000), S. 76.

⁷⁴ Vgl. Hoffmann (1993), S. 29, Heuer (1997), S. 12 und Kinnebrock (1994), S. 17.

3.4 Lernen im künstlichen neuronalen Netz

Die entscheidende Eigenschaft des menschlichen Gehirns, nämlich die Fähigkeit zu lernen, war natürlich der Hauptgrund für die Entwicklung des künstlichen Modells. Während Lernen im biologischen Kontext die Speicherung von Informationen bedeutet,⁷⁵ wird im Bereich der künstlichen neuronalen Netze darunter das Lernen von „Kennwerten“⁷⁶ verstanden. Hierunter sind grundsätzlich die Anpassungen der Eingangsgewichte w_{ij} gemeint.⁷⁷ Die Gewichte können so interpretiert werden, dass in ihnen das Wissen gespeichert ist, d. h. das zu lernende Muster wird über die Gewichtstruktur im künstlichen neuronalen Netz abgelegt und ist damit jederzeit wieder reproduzierbar.⁷⁸

Das Ziel, das damit erreicht werden soll, ist, dass mit bekannten Eingabewerten⁷⁹ die richtigen Ausgabewerte⁸⁰ generiert werden sollen. Als richtig würden jene Werte gelten, die möglichst nahe bei den realen Zielwerten liegen. Diese Fähigkeit wird auch als „*Generalisierungsfähigkeit*“⁸¹ bezeichnet und stellt damit einen entscheidenden Vorteil gegenüber anderen statistischen Modellen dar.

In diesem Zusammenhang ist auch die *Trainingsphase* von der *Reproduktionsphase* zu unterscheiden, denn die Gewichtsanzpassung erfolgt ausschließlich in der Trainingsphase. In der sich anschließenden Reproduktionsphase werden dann dem Netz neue Daten präsentiert, auf Basis derer die korrespondierenden Zielwerte berechnet werden und damit das erlernte Wissen auf neue Daten angewendet wird.

⁷⁵ Vgl. Rojas (1992), S. 20f.

⁷⁶ Vgl. Hoffmann (1993), S. 57.

⁷⁷ Es sei in diesem Zusammenhang darauf hingewiesen, dass unter dem Begriff „Lernen“ theoretisch auch die Anpassung der Netzwerkstruktur subsumiert werden kann. Dies würde zum einen die Verbindungen an sich betreffen, die neu gebildet oder gelöscht werden können, aber auch die stetige Adaptierung der Input-, Aktivierungs- und Outputfunktionen. Sogar die Neubildung und Löschung von kompletten Zellen ist denkbar. Weitere Ausführungen hierzu sind bei Zell (2000), S. 84 zu finden. Im weiteren Verlauf der Arbeit wird allerdings ausschließlich von der Veränderung der Eingangsgewichte ausgegangen, sobald von Lernen die Rede ist.

⁷⁸ Vgl. Köhle (1990), S. 84.

⁷⁹ Im statistischen Kontext entsprechen diese Eingabewerte den unabhängigen Variablen und bestimmen damit die Einflussgrößen des zu untersuchenden Zusammenhangs.

⁸⁰ Analog zu den Eingabewerten stellen die Ausgabewerte die abhängige Variable dar.

⁸¹ Vgl. Dorffner (1991), S. 48 und Nauck (1994), S.30.

Da eine Lernregel sehr stark von der Netzwerkstruktur und der zugrunde liegenden Aufgabe abhängt, werden im Folgenden die wichtigsten Lernregeln überblicksmäßig dargestellt. Aufgrund der Bedeutung des Backpropagation-Algorithmus für die Prognosefähigkeit von künstlichen neuronalen Netzen, wird die hier zugrunde liegende Lernregel in Kapitel 3.4.3.3 ausführlicher erläutert.

3.4.1 Lernaufgaben

Bezüglich der Ziele, die hinter dem Lernen stehen, sind zwei Grundtypen zu unterscheiden, nämlich *assoziatives* („Association“⁸²) und *entdeckendes* („Regularity Detector“⁸³) Lernen.

Ziel des assoziativen Lernens ist es, zu einer präsentierten Menge von Eingabewerten eine zugehörige (assozierte) Menge von Ausgabewerten zu generieren. Folglich müssen während der Trainingsphase dem Netz neben den Eingabedaten auch die dazu korrespondierenden Ausgabedaten vorliegen, um einen Lerneffekt erzielen zu können. In diesem Bereich ist weiterhin zwischen den *autoassoziativen* und *heteroassoziativen* Netzen zu trennen.⁸⁴

Beim autoassoziativen Lernen ist der Eingabevektor identisch mit dem Ausgabevektor, d. h. der Eingabevektor wird mit sich selbst assoziiert. Hintergrund dieses Lerntyps ist, dass damit Muster entweder vervollständigt oder entstört werden sollen, was letztlich einer Korrektur verrauschter Daten gleichkommt.

Heteroassoziatives Lernen hingegen beinhaltet, dass Eingabe- und Ausgabevektor verschieden sind, d. h. zu einem bestimmten Eingabemuster muss ein entsprechendes Ausgabemuster ermittelt werden. In der traditionellen Statistik kann hierfür die Regressionsanalyse als Äquivalent angeführt werden. Eine Variante dieser „*Musterassoziaton*“ („Pattern Associator“) ist das „*Classification Paradigm*“⁸⁵, in welcher das Ausgabemuster eine Klassifikation der Eingabedaten darstellt. Das

⁸² Vgl. Kung (1993), S. 8f.

⁸³ Vgl. Köhle (1990), S. 85 und Rumelhart (1986), S. 161.

⁸⁴ Vgl. Rojas (1993), S. 252f ; Hecht-Nielsen (1989), S.79f und Refenes (1995), S. 7.

⁸⁵ Vgl. Köhle (1990), S. 85 und Rumelhart (1986), S. 161.

bedeutet, dass hiermit die Eingabedaten letztendlich in bestimmte Klassen eingeordnet werden sollen, wobei auch jene Muster richtig klassifiziert werden sollen, die eine zu den trainierten Daten ähnliche Struktur aufweisen. Dies entspricht wiederum dem Kriterium der Generalisierung⁸⁶.

Einen kleinen Überblick gibt unten stehende Abbildung.

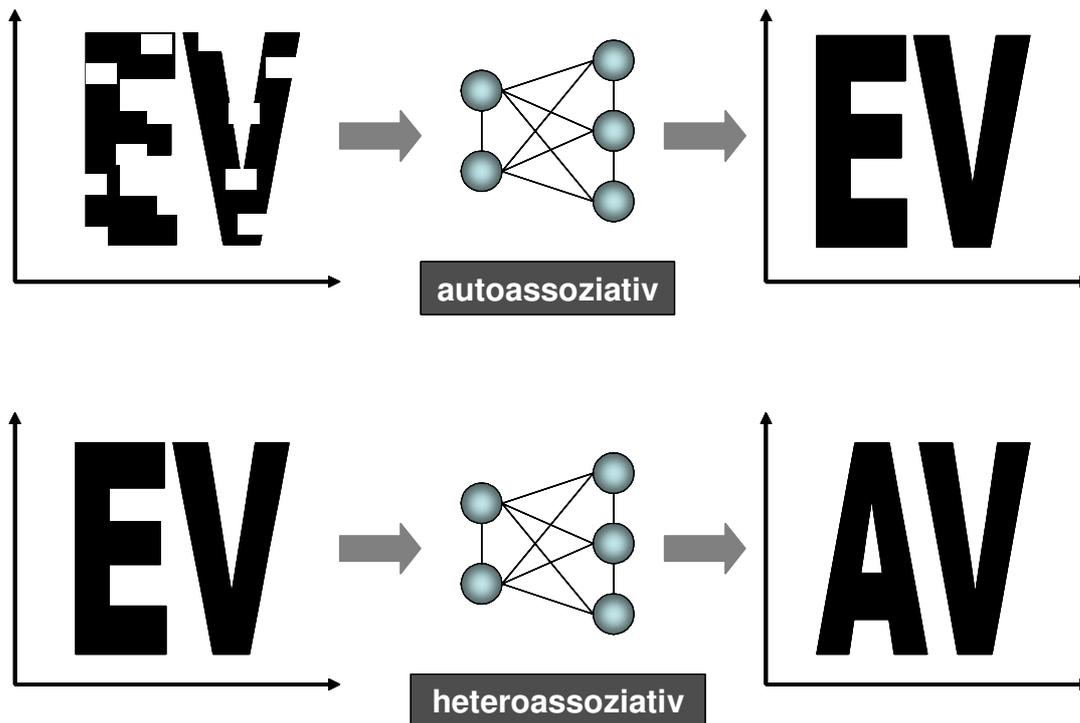


Abbildung 3.7: Assoziatives Lernen

Entdeckendes Lernen bedeutet, dass dem Eingabemuster (EV) kein Ausgabemuster (AV) gegenüber steht. Ziel hierbei ist es, dass das Netz selbständig Muster erkennt und anhand der identifizierten Merkmale die Eingabedaten kategorisiert.⁸⁷ Ein Beispiel hierfür wäre das *Competitive Learning*.

⁸⁶ Vgl. Kung (1993), S. 9f.

⁸⁷ Vgl. Köhle (1993), S. 85 und Kung (1993), S. 9.

3.4.2 Lernkonzepte

Eine weitere Einteilung von künstlichen neuronalen Netzen kann durch die Konzepte, die zum Lernen verwendet werden, erfolgen, wobei folgende Modi existieren:⁸⁸

- Überwachtes Lernen („*supervised training*“)
- Graduelles oder verstärkendes Lernen („*reinforcement training*“)
- Unüberwachtes Lernen („*unsupervised training*“).

Beim *überwachten Lernen* wird bei jedem Lernschritt der vom Netz generierte Ausgabevektor mit den tatsächlichen Zielwerten verglichen. Die Gewichte werden dabei so angepasst, dass eine korrekte Zuordnung der Eingabewerte zu den tatsächlichen Ausgabewerten erzielt wird. Oftmals wird diese Form des Lernens auch als „Lernen unter der Aufsicht eines Lehrers“⁸⁹ bezeichnet. Der Lehrer kennt die richtige Lösung der Aufgabe und kann so die zu lernenden Inhalte ansteuern. Das Lernprinzip, das dahinter steckt ist folgendes: nach jedem Trainingsdurchlauf wird die Abweichung zwischen den berechneten Outputwerten und den Zielwerten ermittelt. Daraufhin werden die Gewichte im Netz so modifiziert, dass der Fehler minimiert wird.

Als Sonderform des überwachten Lernens, das aber in der Literatur häufig als eigenständiges Lernkonzept angeführt wird, ist das *graduelle Lernen*, das auch als *reinforcement training* bekannt ist. Analog zum überwachten Lernen steht dem Eingabemuster auch hier ein bestimmtes Ausgabemuster gegenüber, das möglichst exakt abgebildet werden soll, allerdings wird dem Netz dieses Ausgabemuster nicht konkret mitgeteilt, sondern es erhält lediglich die Information, ob die Anpassung gut oder schlecht war. Diese Information über die Güte der Netzanpassung geschieht dabei über eine (diskrete) Kennziffer, ein sog. „*score*“⁹⁰. Der Vorteil, dass die korrekten Ausgabewerte nicht im Einzelnen vorliegen müssen, wird durch den

⁸⁸ Vgl. hierzu und im Folgenden Hecht-Nielsen (1989), S. 48.

⁸⁹ Vgl. Kinnebrock (1994), S. 31.

⁹⁰ Hecht-Nielsen (1989), S. 49.

Nachteil neutralisiert, dass diese Art von künstlichen neuronalen Netzen weniger leistungsfähig und weniger häufig anwendbar sind als die herkömmlichen Netze mit überwachtem Lernen. Oft werden sie im Bereich der Prozessoptimierung eingesetzt, da hier die Ausprägungen der Zielwerte noch nicht vorliegen, sondern lediglich eine Aussage darüber getroffen werden kann, ob die Gewichtsmodifikation einen Schritt in die richtige Richtung zur weiteren Optimierung des betrachteten Prozesses gebracht hat, oder nicht.

Schließlich existieren noch die Lernregeln des *unüberwachten Trainings* oder *self-organized learnings*. Im Gegensatz zu denen des überwachten Lernens liegen hier keinerlei Informationen über die Richtigkeit des zu erzielenden Outputs vor. Es werden also keine Zielwerte präsentiert, sondern die Gewichte im Netz werden nach anderen Maßstäben modifiziert. Es wird versucht, ähnliche Eingabemuster in ähnliche Kategorien einzuteilen. Im ersten Augenblick erscheint es als widersprüchlich, dass ein Training auch nur auf Basis von Eingabewerten erfolgen kann, allerdings lernt das Netz Ähnlichkeitsmuster in den Eingabedaten und kann so beispielsweise eine Klassifikation von Objekten durchführen, in dem es sie aufgrund gleicher oder ähnlicher Eigenschaftsausprägungen gruppiert.

Zusammenfassend werden die unterschiedlichen Lernregeln überblicksmäßig nochmals aufgeführt und entsprechend eingeordnet. Hierbei wird auch deutlich, dass die einzelnen Kategorien nicht strikt als voneinander isoliert betrachtet werden dürfen, denn assoziatives Lernen ist zugleich auch jeweils überwachtes und entdeckendes, dementsprechend unüberwachtes Lernen.

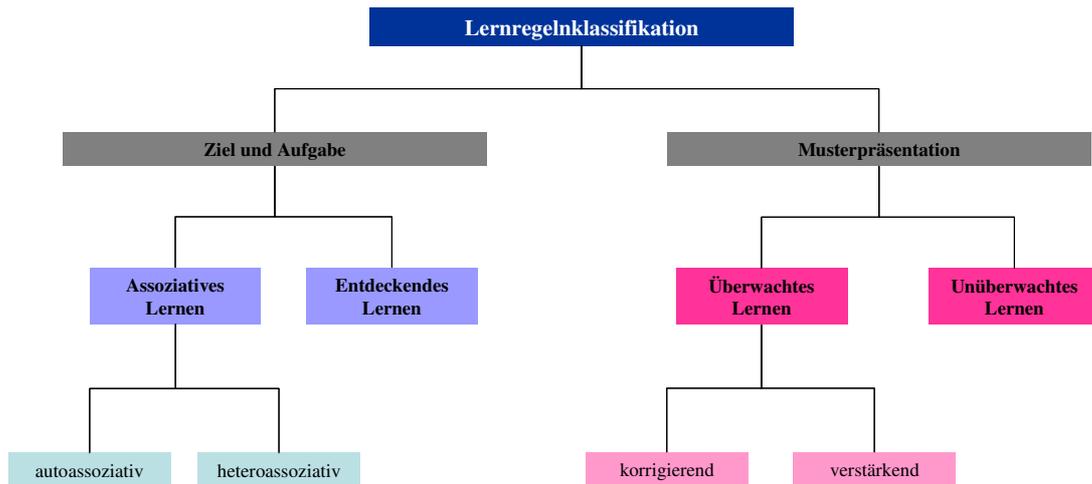


Abbildung 3.8: Übersicht über die verschiedenen Lernregeln

3.4.3 Grundlegende Lernregeln

Prinzipiell gründen die meisten künstlichen neuronalen Netze auf zwei Basislernregeln, die eine Berechnungsvorschrift zur Modifikation der Gewichte w_{ij} angeben. Zum einen ist das die sog. *Hebbsche Lernregel*, die Ausgangspunkt für unüberwachtes Lernen ist und zum anderen die *Delta-Regel*, die vor allem für den später eine wichtige Rolle spielenden Backpropagation-Algorithmus die Basis bildet. Beide Typen werden nun in den folgenden Kapiteln näher dargestellt.

3.4.3.1 Unüberwachtes Lernen: Hebbsche Lernregel

Die Lernregel wurde 1949 von dem Psychologen *Donald Hebb* begründet, der sich hierbei sehr stark am biologischen Vorbild der künstlichen neuronalen Netze orientiert.⁹¹ Im Gehirn erfolgt das Lernen durch Veränderung der Synapsenintensitäten, wobei die Modifikation nach folgendem Prinzip abläuft: Sofern die Neuronen vor und hinter der betrachteten Synapse gleichzeitig aktiv sind, wird die verstärkende Wirkung der Synapse weiter vergrößert, d. h. die Hebb'sche

⁹¹ Vgl. hierzu und im Folgenden Hebb (1949).

Hypothese lautet, dass die „synaptische Eigenschaft (Verstärken oder Hemmen)“ sich proportional zum Produkt von prä- und postsynaptischer Aktivität verhält.⁹²

Auf die künstlichen Modelle übertragen, würde dies bedeuten:⁹³

Sind Neuron i und Neuron j zur gleichen Zeit aktiv, so wird das Verbindungsgewicht w_{ij} zwischen ihnen erhöht.

Im mathematischen Modell ist dies wie folgt umgesetzt:⁹⁴

$$\Delta w_{ij} = \eta o_i a_j$$

mit Δw_{ij} : Änderung der Verbindungsgewichte zwischen Neuron i und Neuron j

η : Lernrate (Konstante)

o_i : Outputwert von Neuron i

a_j : Aktivierungswert von Neuron j .⁹⁵

⁹² Vgl. Kinnebrock (1994), S. 23.

⁹³ Vgl. hierzu und im folgenden Zell (2000), S. 85.

⁹⁴ Es ist zu beachten, dass es sich bei dieser Lernregel bereits um die erweiterte Hebb'sche Lernregel handelt, da sie auf beliebige Outputwerte anwendbar ist. Die ursprüngliche Regel geht von binären Outputwerten aus und wird nach folgendem Maßstab berechnet:

$$\Delta w_{ij} = \begin{cases} \eta & \text{wenn } o_i = o_j = 1 \\ 0 & \text{sonst} \end{cases}.$$

Sofern also beide Neuronen i und j gleichzeitig aktiv sind (die entsprechenden Ausgabewerte der Neuronen haben den Wert 1), wird deren Verbindungsgewicht um einen bestimmten Proportionalitätsfaktor η (vgl. Dorffner (1991), S. 31f) erhöht. Der Nachteil, der sich hieraus ergibt, ist, dass damit nur Gewichtserhöhungen möglich sind und damit bei wiederholtem Lernen die Neuronen einen Sättigungsbereich erreichen. Damit ist allerdings kaum mehr das selektive Verhalten des künstlichen neuronalen Netzes gewährleistet, wobei deren Wirkungsweise extrem reduziert wird. Ein Ausweg ist oft, das Training einem zeitlichen Limit zu unterstellen, damit das Erreichen des Sättigungsbereiches ausgeschlossen wird.

⁹⁵ Streng genommen müsste hier auch stets eine Zeitkomponente t berücksichtigt werden, zumal die Gewichte w_{ij} zeitvariabel sind und sich von Lernschritt zu Lernschritt verändern. Aus Vereinfachungsgründen und in Anlehnung an die Literatur, wird auf diese Berücksichtigung verzichtet.

Somit ergibt sich die Gewichtsänderung jeweils aus dem Produkt vom Aktivierungswert a_j des Neurons j , dem Outputwert o_i und einer Konstanten, der Lernrate η . Die Bedeutung der Lernrate besteht darin, dass sie letztendlich auch das Ausmaß der Gewichtsverstärkung festlegt. Sie liegt im Regelfall zwischen Null und Eins, wobei $\eta = 0$ bedeuten würde, dass kein Lerneffekt erfolgt und $\eta = 1$, dass die Gewichte stark verändert werden, d. h. das Netzwerk würde sich hier das neue Muster so stark merken, dass die bereits erlernten Assoziationen zerstört werden.⁹⁶ Aus diesem Grund würde sich hier empfehlen, die Lernrate auf das offene Intervall $]0;1[$ zu beschränken.

Trotz der Tatsache, dass die im Modell unterstellten Zusammenhänge bis heute in der Neurophysiologie nicht verifiziert werden konnten, finden sie dennoch in unterschiedlichen Ausprägungen in modernen Lernmodellen ihren Eingang. Unter anderem bildet die Hebbsche Lernregel auch die Grundlage für die *Hopfield-Regel*, die ebenfalls ein Lernmodell für unsupervised training darstellt.⁹⁷

Die Hebbsche Lernregel kann allerdings auch so modifiziert werden, dass sie ebenfalls in überwachten Lernverfahren einsetzbar ist. Dazu bedarf es einer Erweiterung der oben aufgeführten Formel, die lautet:⁹⁸

$$\Delta w_{ij} = \eta g(a_j, t_j) h(o_i, w_{ij}).$$

Jetzt ergibt sich die Gewichtsänderung also aus dem Produkt von zwei Funktionen, die wie folgt zu interpretieren sind: $g(a_j, t_j)$ ist eine Funktion in Abhängigkeit von der Aktivierung a_j des Neurons j und der sog. „teaching unit“ t_j , die die erwartete Aktivierung darstellt. Die Funktion $h(o_i, w_{ij})$ hingegen hat als Argumente die Parameter o_i , also den Output der Vorgängerzelle i und das Gewicht von Neuron i zu j .

⁹⁶ Vgl. Köhle (1990), S. 86.

⁹⁷ Vgl. hierzu Hoffmann (1993), S. 92-97; Zell (2000), S. 197-206 und Dorffner (1991), S. 58f.

⁹⁸ Vgl. hierzu und im folgenden Rumelhart (1986), S. 53.

Aus dieser Vorschrift lassen sich nun weitere Lernregeln als Spezialfälle ableiten.

3.4.3.2 Überwachtes Lernen: Delta-Regel

Eine Spezialisierung obiger Hebb'schen Lernregel ist die sog. „Widrow-Hoff-Regel“⁹⁹ oder auch *Delta-Regel*, in der die Gewichts Anpassung proportional zur Differenz δ_j der aktuellen Aktivierung a_j und der erwarteten Aktivierung t_j verläuft.

$$\Delta w_{ij} = \eta \delta_j o_i.$$

Eine Variation hiervon wäre auch folgende Darstellungsform:

$$\Delta w_{ij} = \eta (t_j - o_j) o_i = \eta \delta_j o_i,$$

wobei t_j nun nicht mehr als die erwartete Aktivierung, sondern als *erwartete Ausgabe* zu interpretieren ist. Die Gewichtsmodifikation kann dann auch so interpretiert werden, dass die Fehlerdifferenzen zwischen tatsächlichem und erwartetem Output mit jedem Lernschritt kleiner werden.

Aufgrund der Tatsache, dass die Delta-Regel ohnehin nur auf künstliche neuronale Netze anwendbar ist, die eine einzige Schicht aufweisen, sind beide Darstellungen äquivalent.

Dadurch, dass die Differenz zwischen dem Zielwert und dem tatsächlichen Outputwert in die Berechnung der Gewichte eingehen und nicht mehr der Output von Neuron j , ist auch der Nachteil der Hebb'schen Lernregel aufgehoben, dass die Gewichte nach einer bestimmten Anzahl an Trainingsdurchläufen den Sättigungsbereich erreichen. Die „Übersättigung“¹⁰⁰ wird verhindert, da die Gewichtsänderung mit zunehmenden Lernzyklen immer näher bei den gewünschten

⁹⁹ Vgl. Rumelhart (1986), S. 53.

¹⁰⁰ Dorffner (1991), S. 34.

Ausgabewerten liegen (die Differenz also kleiner wird) und dadurch auch die Gewichte immer weniger stark angepasst werden müssen.

Wie bereits erwähnt, ist die Delta-Regel nur auf Topologien anwendbar, die nur eine Schicht aufweisen und eine lineare Aktivierungsfunktion haben. Aus diesem Grund muss für mehrschichtige Netze mit verdeckten Schichten, die keinen direkten Zieloutput haben, eine Variante der Delta-Regel zum Einsatz kommen. Zu diesem Zweck wurde die *verallgemeinerte Delta-Regel*, die auch unter dem *Backpropagation-Algorithmus* bekannt ist, entwickelt.

3.4.3.3 Überwachtes Lernen: Generalisierte Delta-Regel oder Backpropagation-Algorithmus

3.4.3.3.1 Grundlagen

Die in Kapitel 3.4.3.2 dargestellte Delta-Regel basiert auf der Annahme, dass keine verdeckte Schichten („Hidden-Layer“¹⁰¹) vorliegen, d. h. Neuronen dieser Schicht haben keinen direkten Zugang zur Außenwelt und damit keinen direkten Zieloutput. Allerdings sind mehrschichtige Netzwerke, die aufgrund ihrer abgrenzbaren Lagen in der Literatur auch als „Multi-Layer-Perceptrons“ (MLP)¹⁰² bezeichnet werden, wesentlich flexibler und vielseitiger einsetzbar.¹⁰³

Um die Delta-Regel auch auf diese MLPs anwenden zu können, muss sie erweitert werden, zumal die verdeckten Schichten keinen direkten Zieloutput mehr haben. Nur an der Ausgabeschicht kann der Fehlerterm wieder berechnet werden.

Bei dieser *generalisierten Delta-Regel*¹⁰⁴ wird nun der Fehler durch eine geschickte Anwendung der Kettenregel auf die einzelnen Neuronen verteilt und dadurch die Anpassung der Gewichte erzielt. Er wird also rückwärts durch das Netz gegeben

¹⁰¹ Gurney (1997), S. 65f.

¹⁰² Dorffner (1991), S. 39.

¹⁰³ Vgl. Zell (2000), S. 101.

¹⁰⁴ Nauck (1994), S. 74.

(propagiert), weshalb diese Vorgehensweise auch als „Backpropagation“¹⁰⁵ bezeichnet wird.

Die Netztopologie des MLP funktioniert dabei wie folgt: Da es sich um ein Feedforward-Netz handelt,¹⁰⁶ erfolgt der Informationsfluss nur in einer Richtung, was zur Folge hat, dass die Neuronen der Eingabeschicht die Eingabesignale ohne einer Verarbeitung über gewichtete Verbindungen an die Neuronen der folgenden Schicht weitergeben. Zudem gilt, dass die Zellen einer Schicht jeweils vollständig mit den Neuronen der nachfolgenden Schicht verbunden sind. Des Weiteren werden semilineare Aktivierungsfunktionen unterstellt,¹⁰⁷ was wiederum bedeutet, dass die Aktivierungsfunktion monoton steigend und differenzierbar ist. Dies stellt eine zentrale Annahme dar, da die Ableitungen im weiteren Verlauf der Herleitung des Backpropagation eine wichtige Rolle spielen.

Die Topologie, die sich hieraus ergibt, lässt sich wie folgt grafisch darstellen:

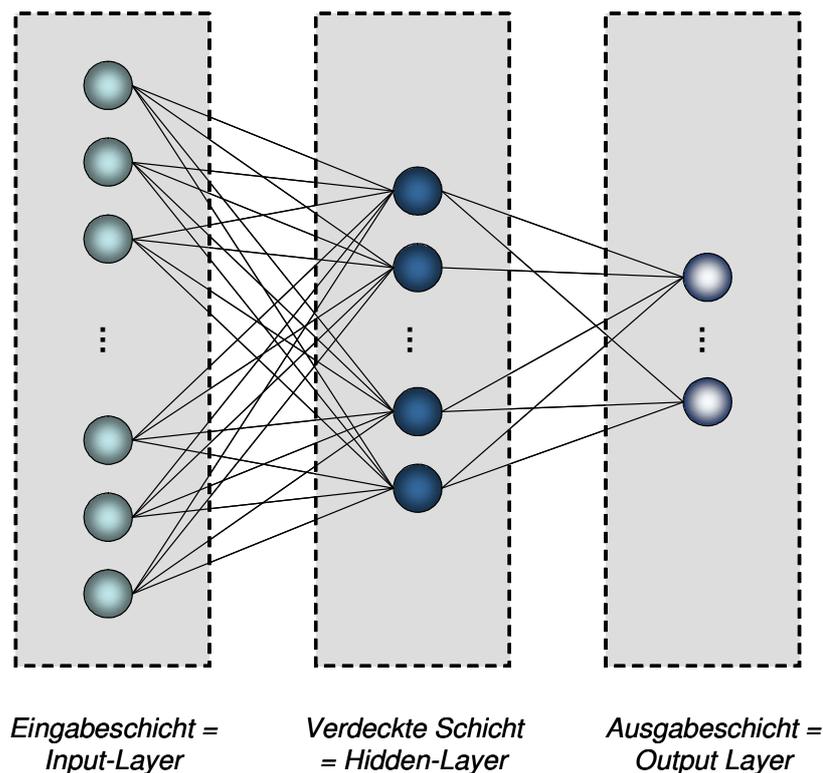


Abbildung 3.9: Schematischer Aufbau eines MLP mit einem Hidden-Layer

¹⁰⁵ Vgl. Brause (1995), S. 240.

¹⁰⁶ Vgl. Köhle (1990), S. 87.

¹⁰⁷ Vgl. Rumelhart (1986), S. 324f.

Die Netzeingabe der verdeckten Lage und der Ausgabeschicht sei weiterhin gegeben durch¹⁰⁸

$$net_j = \sum_i o_i w_{ij} . \quad (3.1)$$

Zudem gilt als Aktivierungsfunktion für Neuron j eine semilineare Funktion

$$a_j = f_{act}(net_j) , \quad (3.2)$$

wobei dies bei Vorliegen der Identitätsfunktion als Outputfunktion auch zugleich dem Ausgabewert o_j entspricht:

$$o_j = f_{act}(net_j) . \quad (3.3)$$

In der Regel werden in der Literatur sigmoide Aktivierungsfunktionen verwendet, wobei hierunter insbesondere die logistische Funktion

$$a_j = f_{act}(net_j) = \frac{1}{1 + e^{-net_j}} \quad (3.4)$$

und die Tangens-Hyperbolicus-Funktion

$$a_j = f_{act}(net_j) = \frac{e^{net_j} - e^{-net_j}}{e^{net_j} + e^{-net_j}} \quad (3.5)$$

fallen.

Deren Ableitungen und Eigenschaften wurden in Kapitel 3.3.2 erläutert und es sei hiermit darauf verwiesen.

¹⁰⁸ Vgl. hierzu und im folgenden Rumelhart (1986), S. 315f, Dorffner (1991), S. 32f und Zell (2000), S. 108f.

Die Outputfunktion in MLPs entspricht meistens der *Identitätsfunktion*, d. h. der Wert der Aktivierungsfunktion ist mit dem Wert der Ausgabefunktion des betrachteten Neurons identisch, wodurch im Folgenden nicht mehr zwischen Aktivierungs- und Outputfunktion explizit unterschieden wird. Mit $f(net_j)$ ist deshalb künftig immer die Aktivierungsfunktion gemeint.

3.4.3.3.2 Herleitung des Backpropagation-Algorithmus

Wie bereits angedeutet, besteht das Prinzip des Backpropagation darin, die Verbindungsgewichte w_{ij} zwischen Neuron i und Neuron j so anzupassen, dass sie in Abhängigkeit der Differenz von Zielausgabe und tatsächlicher Ausgabe proportional modifiziert werden.

Somit kann eine *Fehlerfunktion* („measure of error“¹⁰⁹) definiert werden:¹¹⁰

$$E_p = \frac{1}{2}(t_{pj} - o_{pj})^2. \quad (3.6)$$

mit t_{pj} : Sollausgabewert des Ausgabeneurons j für Trainingsmuster p

o_{pj} : Istausgabewert des Ausgabeneurons j für Trainingsmuster p .

E_p steht hierbei für den Fehler im Trainingsmuster (pattern) p über alle Ausgabe-Units j (mit $j = 1, 2, \dots, M$) und entspricht letztlich der quadrierten Abweichung des tatsächlichen Ausgabewerts von der Teaching Unit, wobei die Quadrierung wiederum dazu dient, dass sich positive und negative Abweichungen im Mittel nicht aufheben.

¹⁰⁹ Vgl. Rumelhart (1986), S. 323.

¹¹⁰ Vgl. hierzu und im Folgenden Zell (2000), S. 108f; Dorffner (1991), S. 32f.

Der Gesamtfehler des Netzwerkes lässt sich dann berechnen aus:¹¹¹

$$E = \frac{1}{2} \sum_p E_p = \frac{1}{2} \sum_p \sum_j (t_{pj} - o_{pj})^2. \quad (3.7)$$

Ziel ist es nun, diesen Gesamtfehler zu minimieren (im Idealfall würde gelten: $E = 0$). Diese Minimierung wiederum soll durch die entsprechende Anpassung der Verbindungsgewichte geschehen.

Stellt man die Fehlerfunktion in Abhängigkeit der Gewichte w_{ij} dar, so kann E als Hypergebirge in einem n -dimensionalen Verbindungsstärkenraum dargestellt werden.¹¹² Um dies zu veranschaulichen, wird hierzu exemplarisch ein derartiges Fehlergebirge im zweidimensionalen Raum dargestellt:

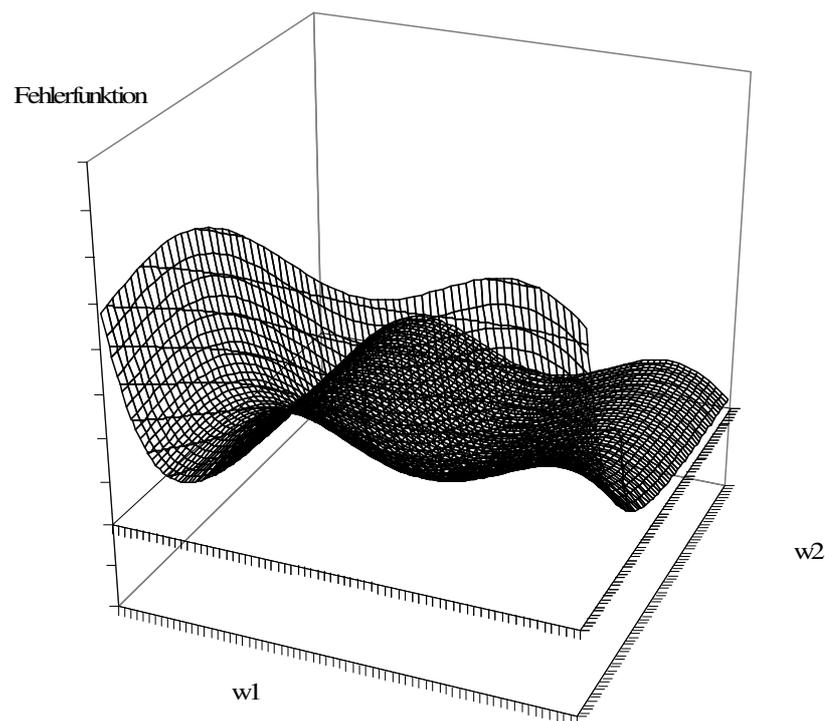


Abbildung 3.10: Fehlergebirge im zweidimensionalen Raum

¹¹¹ Vgl. Poddig (1992), S. 243.

¹¹² Vgl. Poddig (1992), S. 267.

Gesucht wird also jene Gewichtungskombination, die die Fehlerfunktion minimiert, was übertragen auf das Fehlergebirge bedeutet, dass das globale Minimum gesucht wird.

Es gilt also:

$$E_p(w) \xrightarrow[w]{\text{Min!}} \quad (3.8)$$

Das Verfahren, das sich hierbei anbietet, ist das Gradientenverfahren. Ausgehend von einem zufällig gewählten Startpunkt auf der Fehleroberfläche wird das Minimum auf Grundlage des steilsten Abstiegs in diesem Punkt gesucht.

Das Prinzip soll anhand eines kleinen, einfachen Schaubilds verdeutlicht werden:

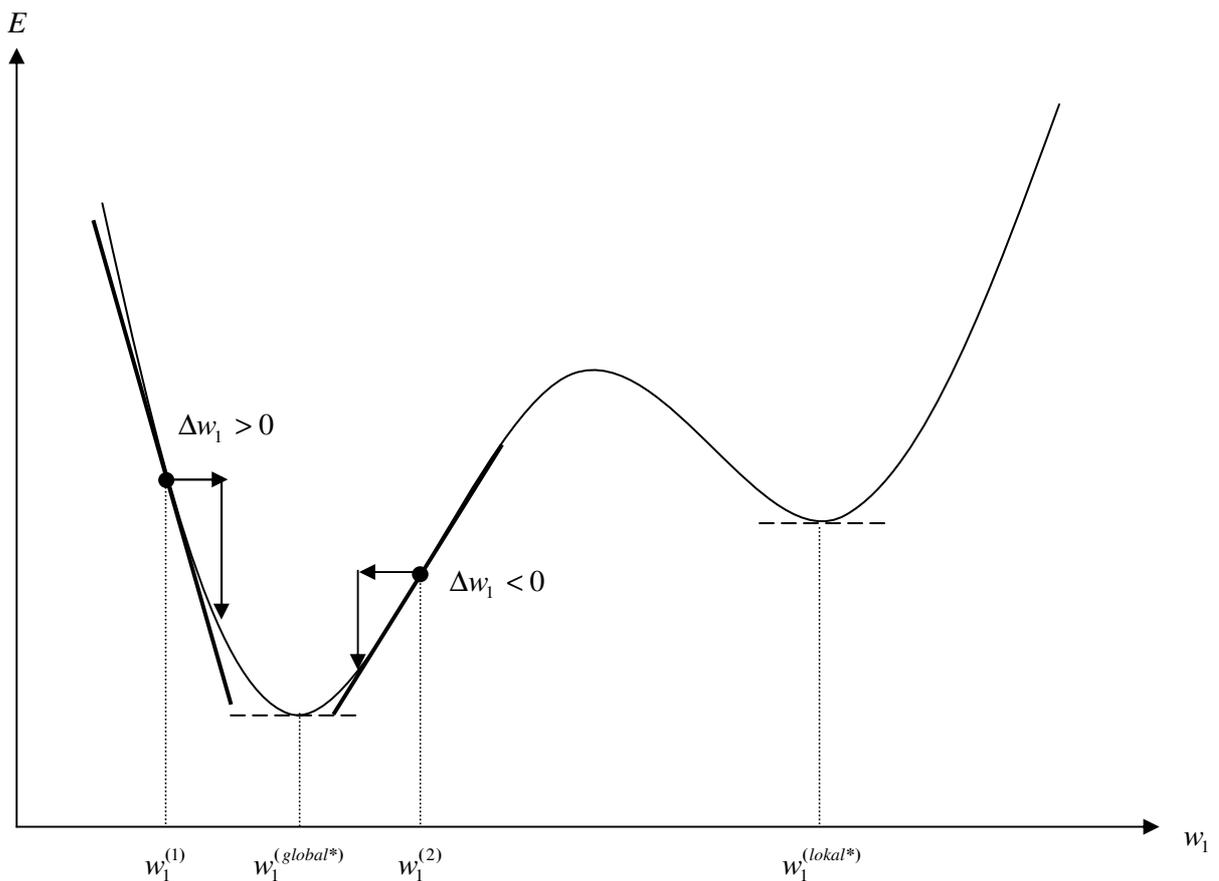


Abbildung 3.11: Prinzip des Gradientenabstiegsverfahrens, eigene Darstellung in Anlehnung an Rigoll (1993), S. 74

Das erstrebte Ziel sei das globale Minimum $w_1^{(global*)}$. Ausgehend vom Startpunkt $w_1^{(1)}$ lässt sich unter der Voraussetzung der Kenntnis der Ableitung der Fehlerfunktion, das Minimum erreichen, indem folgendermaßen vorgegangen wird: In $w_1^{(1)}$ ist die Steigung von E negativ, also $E'(w_1^{(1)}) < 0$. Um sich in Richtung $w_1^{(global*)}$ zu bewegen, muss w_1 erhöht werden ($\Delta w_1 > 0$).

Analoges gilt für den Ausgangspunkt $w_1^{(2)}$. Hier ist die erste Ableitung $E'(w_1^{(2)}) > 0$, d. h. das Gewicht w_1 muss nun weiter verringert werden, um das globale Minimum der Fehlerfunktion zu erreichen ($\Delta w_1 < 0$).

Folglich kann als Zusammenhang zwischen erster Ableitung der Fehlerfunktion und notwendiger Gewichtsanzpassung folgendes festgehalten werden:¹¹³

Die Modifikation von Δw_{ij} erfolgt jeweils in Abhängigkeit des negativen Gradienten der Fehlerfunktion an der betrachteten Stelle:¹¹⁴

$$\Delta w = -\eta \nabla E \quad (3.9)$$

bzw. für ein Element:

$$\Delta w_{ij} = -\eta \frac{\partial E}{\partial w_{ij}} = -\eta \sum_p \frac{\partial E_p}{\partial w_{ij}} . \quad (3.10)$$

Sofern diese Bedingung erfüllt ist, nimmt auch der Fehler ab: $\frac{\partial E_p}{\partial w_{ij}} < 0$.

Der Fehler E_p kann gemäß (3.6) auch in Abhängigkeit der Outputwerte der Vorgängereinits o_i geschrieben werden, denn es gilt:

$$o_j = f(net_j) \quad (3.11)$$

¹¹³ Auch hier wird im Folgenden aus Vereinfachungsgründen der Index p für den Sollausgabewert und den Istausgabewert in der Formeldarstellung vernachlässigt. Es gilt also: t_j und o_j .

¹¹⁴ Vgl. Zell (2000), S. 106.

und

$$net_j = \sum_i w_{ij} o_i, \quad (3.12)$$

so dass unter Verwendung der Kettenregel nun anzusetzen ist:

$$\frac{\partial E_p}{\partial w_{ij}} = \frac{\partial E_p}{\partial net_j} \cdot \frac{\partial net_j}{\partial w_{ij}}. \quad (3.13)$$

Unter Beachtung von (3.12) folgt

$$\frac{\partial net_j}{\partial w_{ij}} = \frac{\partial \sum_i w_{ij} o_i}{\partial w_{ij}} = o_i. \quad (3.14)$$

In der Literatur wird zudem

$$\delta_j = -\frac{\partial E_p}{\partial net_j} \quad (3.15)$$

als *Fehlersignal*¹¹⁵ definiert, so dass die Gewichtsänderung Δw_{ij} auch ausgedrückt werden kann als:

$$\Delta w_{ij} = \eta \delta_j o_i. \quad (3.16)$$

Um δ_j wiederum zu berechnen, wird erneut die Kettenregel angewendet, da die partielle Ableitung als Ergebnis zweier Faktoren zu interpretieren ist. Das Fehlersignal δ_j ist nämlich nicht nur von der Änderung des Outputs o_i , sondern auch von der Änderung des Netto-Inputs net_j abhängig:

¹¹⁵ Vgl. Zell (2000), S. 108.

$$\delta_j = -\frac{\partial E_p}{\partial net_j} = -\frac{\partial E_p}{\partial o_j} \cdot \frac{\partial o_j}{\partial net_j}. \quad (3.17)$$

Der zweite Faktor der Gleichung (3.17), nämlich $\frac{\partial o_j}{\partial net_j}$ kann wegen (3.11) umformuliert werden in

$$\frac{\partial o_j}{\partial net_j} = f'(net_j), \quad (3.18)$$

und repräsentiert letztlich die erste Ableitung der Aktivierungsfunktion von Neuron j .

Was nun noch bleibt, ist, den ersten Faktor $\left(-\frac{\partial E_p}{\partial o_j}\right)$ zu verifizieren.

Während für den zweiten Faktor die Zusammenhänge sowohl für die Ausgabezellen, als auch bei den Neuronen der verdeckten Schicht gelten, muss nun in diesem Fall genauer differenziert werden.

Zunächst wird angenommen, es handle sich um eine Outputunit. Gemäß (3.6) folgt dabei:

$$-\left(\frac{\partial E_p}{\partial o_j}\right) = \frac{\partial \frac{1}{2} \sum_j (t_j - o_j)^2}{\partial o_j} = (t_j - o_j). \quad (3.19)$$

Somit gilt für den Fall von Ausgabezellen zusammenfassend für das Fehlersignal δ_j :

$$\delta_j = (t_j - o_j) \cdot f'(net_j) \quad (3.20)$$

und für die Gewichts Anpassung Δw_{ij} :

$$\Delta w_{ij} = \eta(t_j - o_j) \cdot f'(net_j) o_i = \eta \delta_j o_i. \quad (3.21)$$

Dies würde also bereits der verallgemeinerten Delta-Regel für *zweilagige* Netzwerke entsprechen. Es sollen nun aber mehrschichtige Netze betrachtet werden, so dass im Weiteren unterstellt wird, dass es sich bei dem Index j nicht mehr um eine Zelle der Ausgabeschicht, sondern um eine verdeckte Schicht handelt.

Aus dieser Prämisse heraus muss wiederum $\left(-\frac{\partial E_p}{\partial o_j}\right)$ ermittelt werden. Dies ist allerdings nicht mehr direkt möglich, so dass über einen kleinen Umweg und durch erneuter Anwendung der Kettenregel unter Zuhilfenahme der Zusammenhänge aus (3.1) und (3.15) eine Lösung gefunden werden kann.

$\left(-\frac{\partial E_p}{\partial o_j}\right)$ lässt sich nun wieder in zwei Faktoren aufspalten, nämlich in die

Veränderung des Faktors E_p aufgrund der Veränderung der Nettoinputs net_k der nächst höheren Schicht k (vgl. (3.1)) und in die Veränderung von net_k selber aufgrund der Veränderung der Ausgabewerte o_j :

$$\begin{aligned} \left(-\frac{\partial E_p}{\partial o_j}\right) &= -\sum_k \frac{\partial E_p}{\partial net_k} \cdot \frac{\partial net_k}{\partial o_j} = & (3.22) \\ &= \sum_k \left(-\frac{\partial E_p}{\partial net_k}\right) \cdot \frac{\partial \sum_i o_i w_{ik}}{\partial o_j} = \\ &= \sum_k \delta_k w_{jk}. \end{aligned}$$

Damit gilt für das Fehlersignal δ_j :

$$\delta_j = f'(net_j) \cdot \sum_k \delta_k w_{jk}. \quad (3.23)$$

Zusammengefasst bedeutet dies, dass das Fehlersignal δ_j des Neurons j einer verdeckten Schicht aus den Fehlersignalen der nächst höheren Schichten ermittelt werden kann. Die Fehler werden also rekursiv durch die Schichten zurückpropagiert, weshalb hiervon auch der Name „*Backpropagation*“ abgeleitet wurde. Zusammenfassend gilt somit für die verallgemeinerte Delta-Regel:

$$\Delta w_{ij} = \eta \delta_j o_i \quad (3.24)$$

mit

$$\delta_j = \begin{cases} (t_j - o_j) f'(net_j), & \text{falls } j \text{ Output - Unit} \\ \sum_k \delta_k w_{jk} f'(net_j), & \text{falls } j \text{ Hidden - Unit} \end{cases}$$

Um obigen Zusammenhang noch näher zu spezifizieren, wird weiterhin angenommen, dass als Aktivierungsfunktion zum einen die logistische und zum anderen die Tangens Hyperbolicus Funktion angewendet werden.

Wie bereits in Kapitel 3.3.2 gezeigt wurde, ist die erste Ableitung der logistischen Funktion

$$\frac{\partial o_j}{\partial net_j} = f'(net_j) = o_j(1 - o_j) \quad (3.25)$$

und sie weist jene Eigenschaften auf, die gerade für die Anwendung im Backpropagation essentiell sind. So ist sie stetig und im gesamten Definitionsbereich $(-\infty < net_j < \infty)$ auch differenzierbar. Der Wertebereich erstreckt sich auf das Intervall $]0;1[$, woraus allerdings ein wesentlicher Nachteil im Zusammenhang mit dem Lernen in künstlichen neuronalen Netzen resultiert. Denn im Falle einer Nichtaktivierung eines Neurons, ergibt sich gemäß dem Wertebereich der Wert Null als Outputwert. Dieser wiederum geht dann als Produkt in die Formel (3.25) und letztendlich auch in (3.24) ein, wodurch die Gewichtsadaption umso geringer

ausfällt, je näher der Wert bei Null liegt bzw. im Extremfall sogar verhindert wird. Dieser Umstand ist allerdings nicht immer erwünscht, so dass nach einer Lösung dieses Problems gesucht werden muss. In der Literatur wird hierfür folgende Modifikation der logistischen Funktion empfohlen:¹¹⁶

Der Funktion wird ein Schwellenwert $\theta = \frac{1}{2}$ hinzugefügt, der bewirkt, dass sich die Funktion in ihrem Wertebereich nach unten verschiebt, d. h. die logistische Funktion würde dann nur noch Werte im Intervall $\left[-\frac{1}{2}; \frac{1}{2}\right]$ annehmen und hätte folgende formale Form:

$$o_j = \frac{1}{1 + e^{-net_j}} - \frac{1}{2}. \quad (3.26)$$

Eine andere Möglichkeit besteht darin, völlig auf die logistische Funktion als Aktivierungsfunktion zu verzichten und auf den Tangens Hyperbolicus überzugehen. Dieser weist dieses Problem der Verhinderung von Gewichtsänderungen nicht auf, zumal er ohnehin einen Wertebereich von $]-1; +1[$ aufweist. Das Lernen wird hiermit also erleichtert, zumal nun bei einer Nichtaktivierung des Vorgängerneurons, das Gewicht trotzdem verändert wird (in diesem Fall reduziert, da die Aktivierungsfunktion einen Wert nahe bei -1 annimmt).

Die erste Ableitung der Tangens Hyperbolicus Funktion ist:

$$\begin{aligned} \frac{\partial o_j}{\partial net_j} = f'(net_j) &= \frac{(e^{net_j} + e^{-net_j})(e^{net_j} + e^{-net_j}) - (e^{net_j} - e^{-net_j})(e^{net_j} - e^{-net_j})}{(e^{net_j} + e^{-net_j})^2} = \\ &= 1 - \tanh^2(net_j) \end{aligned} \quad (3.27)$$

Außerdem kann die Tangens Hyperbolicus Funktion auch als Funktion der Logistischen Funktion dargestellt werden:

¹¹⁶ Vgl. Zell (2000), S. 114.

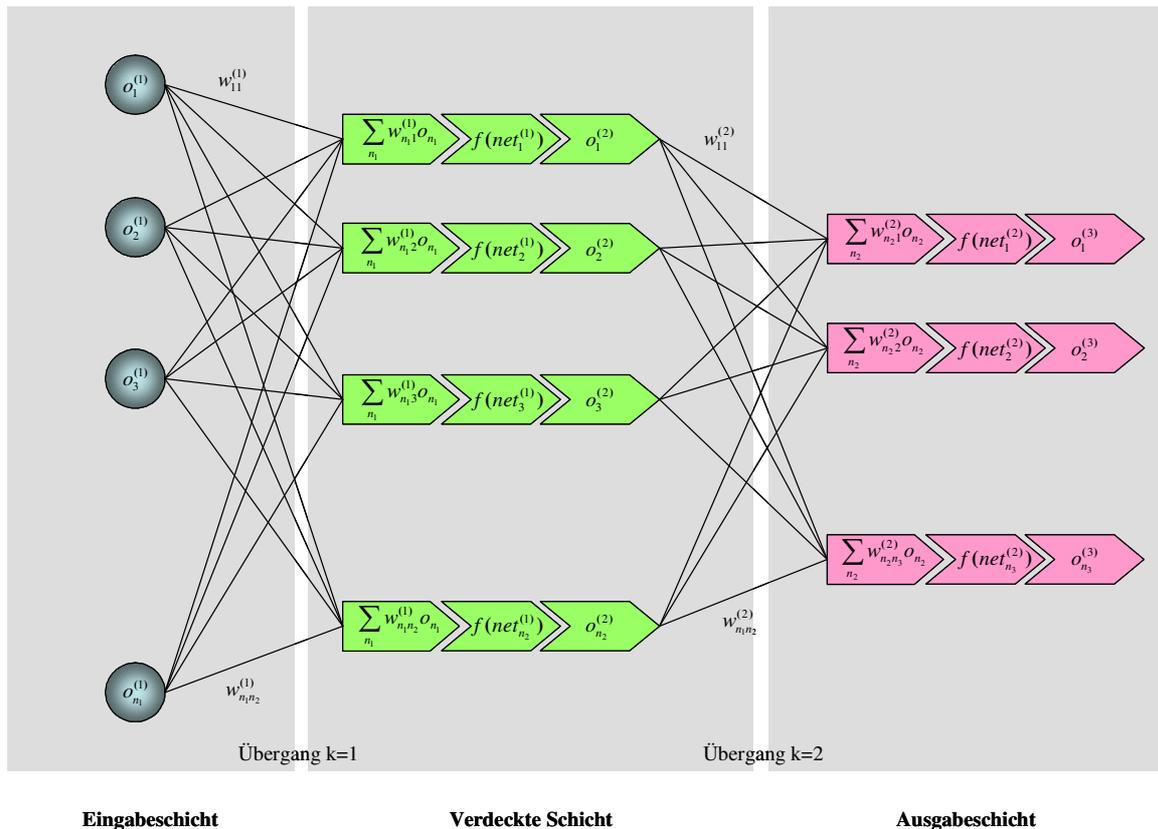
$$\tanh(\text{net}_j) = \frac{e^{\text{net}_j} - e^{-\text{net}_j}}{e^{\text{net}_j} + e^{-\text{net}_j}} = 2f_{\log}(2\text{net}_j) - 1. \quad (3.28)$$

3.4.3.3 Formale Berechnung der Gewichts Anpassung in einem dreistufigen Netzwerk mit einer verdeckten Schicht

Nachdem in den vorherigen Kapiteln der Backpropagation Algorithmus zur Gewichts Anpassung in MLPs allgemein dargestellt worden ist, soll jetzt anhand eines konkreteren Beispiels die Vorgehensweise näher erläutert werden.

Der Grund, weshalb hier exemplarisch ein Netzwerk mit insgesamt drei Layern und einer verdeckten Schicht gewählt wurde, liegt darin, dass speziell diese Topologie auch im praktischen Teil der Arbeit eine zentrale Rolle spielen wird.

Um die Eindeutigkeit der Indizes und Variablen zu gewähren, wird im Folgenden eine geringfügige Modifikation der Notationen vorgenommen. Eine erste Übersicht dazu soll unten stehende Abbildung liefern.


Abbildung 3.12: MLP mit einem Hidden Layer

Das Netz besteht also aus der Eingabeschicht ($l=1$) mit n_1 Neuronen, einer verdeckten Schicht ($l=2$) mit n_2 und der Ausgabeschicht ($l=3$) mit insgesamt n_3 Units. Die Erklärung zu den weiteren Notationen ist wie folgt:

$o_{i_1}^{(1)}$: Wert des Inputneurons i_1 in Schicht (1), ($1 \leq i_1 \leq n_1$),

$o_{i_2}^{(2)}$: Output des Neurons i_2 in Schicht (2), ($1 \leq i_2 \leq n_2$),

$o_{i_3}^{(3)}$: Output des Neurons i_3 in Schicht (3), ($1 \leq i_3 \leq n_3$),

$\text{net}_{i_2}^{(1)}$: Netto-Input des Neurons i_2 in Schicht (2), das aus Schicht (1) resultiert, ($1 \leq i_2 \leq n_2$),

$\text{net}_{i_3}^{(2)}$: Netto-Input des Neurons i_3 in Schicht (3), das aus Schicht (2) resultiert, ($1 \leq i_3 \leq n_3$),

$w_{i_1 i_2}^{(1)}$: Verbindungsgewicht am Übergang von Neuron i_1 in Schicht (1) nach Neuron i_2 in Schicht (2), also $k=1$,

$w_{i_2 i_3}^{(2)}$: Verbindungsgewicht am Übergang von Neuron i_2 in Schicht (2) nach Neuron i_3 in Schicht (3), also $k = 2$.

Des Weiteren wird davon ausgegangen, dass als Aktivierungsfunktion die logistische Funktion mit ihren in Kapitel 3.3.2 dargestellten Eigenschaften angewendet wird.

Die Konnektionsmatrix, wie sie in Kapitel 3.1.2.2 eingeführt wurde, kann in diesem Fall auch folgendermaßen dargestellt werden, wobei in den einzelnen Feldern jeweils die Verbindungsgewichte zwischen den Input-Neuronen (IN), den Hidden Neuronen (HN) und den Output-Neuronen (ON) dargestellt sind:

$$\underline{W} = \begin{pmatrix} \text{IN untereinander} & \text{IN zu HN} & \text{IN zu ON} \\ \text{HN zu IN} & \text{HN untereinander} & \text{HN zu ON} \\ \text{ON zu IN} & \text{ON zu IN} & \text{ON untereinander} \end{pmatrix}. \quad (3.29)$$

Damit können die Gewichte in den einzelnen Schichten wiederum zusammengefasst werden in $W^{(1)}$ für $w_{i_1 i_2}^{(1)}$ und $W^{(2)}$ für $w_{i_2 i_3}^{(2)}$. Zumal es per definitionem in MLPs nur jeweils die Units der benachbarten Schichten miteinander vollständig verbunden sind, folgt, dass die Verbindungen außer $W^{(1)}$ und $W^{(2)}$ jeweils Null sind:

$$\underline{W} = \begin{pmatrix} 0 & W^{(1)} & 0 \\ 0 & 0 & W^{(2)} \\ 0 & 0 & 0 \end{pmatrix}. \quad (3.30)$$

Die Zielfunktion (3.8) kann nun auch nach obiger Notation abgeändert werden:

$$E = \frac{1}{2} \sum_{i_3=1}^{n_3} (t_{i_3} - o_{i_3}^{(3)})^2 \rightarrow \text{Min.}! \quad (3.31)$$

Wie bereits dargestellt, wird der Netzfehler über die verdeckten Schichten bis hin zur Eingabeschicht zurückpropagiert, um dann ein Indikator zu erhalten, anhand dessen die Gewichtsmodifikation erfolgen kann.

An der Ausgabeschicht lässt sich also am Neuron i_3 folgender Output $o_{i_3}^{(3)}$ berechnen:

$$\begin{aligned} o_{i_3}^{(3)} &= f(\text{net}_{i_3}^{(2)}) = f\left(\sum_{i_2=1}^{n_2} w_{i_2 i_3}^{(2)} o_{i_2}^{(2)}\right) = f\left(\sum_{i_2=1}^{n_2} w_{i_2 i_3}^{(2)} f(\text{net}_{i_2}^{(1)})\right) = \\ &= f\left(\sum_{i_2=1}^{n_2} w_{i_2 i_3}^{(2)} f\left(\sum_{i_1=1}^{n_1} w_{i_2 i_3}^{(1)} o_{i_1}^{(1)}\right)\right), \end{aligned} \quad (3.32)$$

mit $1 \leq i_3 \leq n_3$,

wobei hieraus dann für die Minimierungsfunktion folgt:

$$E = \frac{1}{2} \sum_{i_3=1}^{n_3} (t_{i_3} - o_{i_3}^{(3)})^2 = \frac{1}{2} \sum_{i_3=1}^{n_3} \left(t_{i_3} - f\left(\sum_{i_2=1}^{n_2} w_{i_2 i_3}^{(2)} f\left(\sum_{i_1=1}^{n_1} w_{i_2 i_3}^{(1)} o_{i_1}^{(1)}\right)\right) \right)^2. \quad (3.33)$$

Im ersten Schritt werden die Gewichte zufällig vorinitialisiert¹¹⁷, so dass von einer anfänglichen Gewichtsmatrix zum Trainingszeitpunkt ($t=0$) mit $W^{(1)}(0)$ und $W^{(2)}(0)$ auszugehen ist. Auf dieser Basis ergibt sich dann die erste

¹¹⁷ Wobei hierbei das Problem des „Symmetry Breaking“ (Rumelhart (1986), S. 330f) beachtet werden muss, das besagt, dass die Startgewichte nicht alle gleich groß sein dürfen, weil dann das System nicht lernen kann. Dies resultiert daraus, da der Fehler proportional zu den Gewichtswerten zurückgegeben wird und so vor allem in dreistufigen Netzwerken die verdeckte Schicht keine Gewichtsänderung mehr annehmen kann. Dieses Problem kann aber dadurch behoben werden, in dem kleine zufällige Initialwerte gewählt werden. Sofern diese Werte auch noch nahe bei Null liegen, ergibt sich ein weiterer Vorteil: da die Ableitung der Sigmoidfunktion hier am größten ist kann sich das Netz rasch selbst adaptieren. Köhle (1990, S. 96) empfiehlt in diesem Zusammenhang auch eine Initialisierung in Abhängigkeit von der Anzahl der zu jeder einzelnen Unit führenden Verbindungen:

$$\text{Initialisierung} = \frac{\text{Konstante}}{\sqrt{\text{Anzahl der zu dieser Unit hinführenden Verbindungen}}}.$$

Leider wird allerdings bezüglich der Konstanten keine näheren Angaben gemacht, sondern es wird empfohlen, diese „experimentell“ zu bestimmen. Somit ist dieser Vorschlag eher unbefriedigend.

Fehlerberechnung und damit kann gemäß dem Gradientenabstiegsverfahrens die erste Gewichtsänderung $\Delta w_{ij}^{(k)}$ wie folgt errechnet werden:

$$\Delta w_{ij}^{(k)}(1) = -\eta \left. \frac{\partial E}{\partial w_{ij}^{(k)}} \right|_{w_{ij}^{(k)} = w_{ij}^{(k)}(0)} \quad (3.34)$$

Im vorausgegangenen Kapitel wurde bereits festgestellt, dass eine Fallunterscheidung beachtet werden muss. Je nachdem ob es sich um eine Output- oder verdeckte Schicht handelt, muss die Ableitung bzw. das Fehlersignal nach anderen Maßstäben berechnet werden.

Hier in diesem Beispiel wird von einem dreistufigen künstlichen neuronalen Netz mit einer verdeckten Schicht ausgegangen. Somit würde $k=2$ die Outputschicht und $k=1$ die Hidden-Schicht bezeichnen.

Analog zu (3.13) gilt nun für die Outputschicht $k=2$:

$$\frac{\partial E}{\partial w_{ij}^{(2)}} = \sum_{i_3=1}^{n_3} \frac{\partial E}{\partial o_{i_3}^{(3)}} \cdot \frac{\partial f(net_{i_3}^{(2)})}{\partial net_{i_3}^{(2)}} \cdot \sum_{i_2=1}^{n_2} \frac{\partial net_{i_3}^{(2)}}{\partial w_{i_2 i_3}^{(2)}} \cdot \frac{\partial w_{i_2 i_3}^{(2)}}{\partial w_{ij}^{(2)}} \quad (3.35)$$

Für die einzelnen Faktoren lassen sich weiterhin folgende Zusammenhänge ableiten:

$$\frac{\partial E}{\partial o_{i_3}^{(3)}} = -(t_{i_3} - o_{i_3}^{(3)}), \quad (3.35a)$$

und

$$\frac{\partial f(net_{i_3}^{(2)})}{\partial net_{i_3}^{(2)}} = f(net_{i_3}^{(2)}) \cdot (1 - f(net_{i_3}^{(2)})) = o_{i_3}^{(3)} (1 - o_{i_3}^{(3)}), \quad (3.35b)$$

wobei nochmals angemerkt sei, dass die logistische Funktion als Aktivierungsfunktion unterstellt wird;

$$\frac{\partial net_{i_3}^{(2)}}{\partial w_{i_2 i_3}^{(2)}} = o_{i_2}^{(2)}; \quad (3.35c)$$

$$\frac{\partial w_{i_2 i_3}^{(2)}}{\partial w_{ij}^{(2)}} = \begin{cases} 1 & \text{für } (i, j) = (i_2, i_3) \\ 0 & \text{sonst} \end{cases}, \quad (3.35d)$$

so dass letztendlich die Formel

$$\frac{\partial E}{\partial w_{ij}^{(2)}} = -(t_{i_3} - o_{i_3}^{(3)}) o_{i_3}^{(3)} (1 - o_{i_3}^{(3)}) o_{i_2}^{(2)} \quad (3.36)$$

resultiert und die Anpassung der Gewichte nach folgender Regel erfolgen kann:

$$\begin{aligned} \Delta w_{ij}^{(2)} &= -\eta \frac{\partial E}{\partial w_{ij}^{(2)}} = -\eta (-(t_{i_3} - o_{i_3}^{(3)}) o_{i_3}^{(3)} (1 - o_{i_3}^{(3)}) o_{i_2}^{(2)}) = \\ &= \eta (t_{i_3} - o_{i_3}^{(3)}) o_{i_3}^{(3)} (1 - o_{i_3}^{(3)}) o_{i_2}^{(2)}. \end{aligned} \quad (3.37)$$

Für den zweiten Fall, nämlich den der Gewichtsangpassung zwischen der Input- und Hidden-Schicht, lassen sich die im nächsten Abschnitt dargestellten Zusammenhänge ableiten.

Die Fehlerfunktion muss allgemein nach den Gewichten der Inputschicht $w_{ij}^{(1)}$ differenziert werden:

$$\frac{\partial E}{\partial w_{ij}^{(1)}}. \quad (3.38)$$

Auch hierfür wurde schon theoretisch gezeigt, dass die Fehlersignale der nachgelagerten Schichten ins Kalkül miteinbezogen werden müssen.

$$\frac{\partial E}{\partial w_{ij}^{(1)}} = \sum_{i_3=1}^{n_3} \frac{\partial E}{\partial o_{i_3}^{(3)}} \cdot \frac{\partial f(net_{i_3}^{(2)})}{\partial net_{i_3}^{(2)}} \cdot \sum_{i_2=1}^{n_2} \frac{\partial net_{i_3}^{(2)}}{\partial o_{i_2}^{(2)}} \cdot \frac{\partial f(net_{i_2}^{(1)})}{net_{i_2}^{(1)}} \cdot \sum_{i_1=1}^{n_1} \frac{\partial net_{i_2}^{(1)}}{\partial w_{i_1 i_2}^{(1)}} \cdot \frac{\partial w_{i_1 i_2}^{(1)}}{\partial w_{ij}^{(1)}}. \quad (3.39)$$

Werden die einzelnen Faktoren wieder näher betrachtet, so resultiert im Einzelnen:

$$\sum_{i_3=1}^{n_3} \frac{\partial E}{\partial o_{i_3}^{(3)}} = -\sum (t_{i_3} - o_{i_3}^{(3)}); \quad (3.39a)$$

$$\frac{\partial f(net_{i_3}^{(2)})}{\partial net_{i_3}^{(2)}} = o_{i_3}^{(3)}(1 - o_{i_3}^{(3)}); \quad (3.39b)$$

$$\frac{\partial net_{i_3}^{(2)}}{\partial o_{i_2}^{(2)}} = w_{i_2 i_3}^{(2)}; \quad (3.39c)$$

$$\frac{\partial f(net_{i_2}^{(1)})}{net_{i_2}^{(1)}} = o_{i_2}^{(2)}(1 - o_{i_2}^{(2)}); \quad (3.39d)$$

$$\frac{\partial net_{i_2}^{(1)}}{\partial w_{i_1 i_2}^{(1)}} = o_{i_2}^{(2)}(1 - o_{i_2}^{(2)}); \quad (3.39e)$$

$$\frac{\partial w_{i_1 i_2}^{(1)}}{\partial w_{ij}^{(1)}} = \begin{cases} 1 & \text{für } (i, j) = (i_1, i_2) \\ 0 & \text{sonst} \end{cases}, \quad (3.39f)$$

wobei dann in der Zusammenfassung wieder gilt:

$$\frac{\partial E}{\partial w_{ij}^{(1)}} = -\sum_{i_3=1}^{n_3} (t_{i_3} - o_{i_3}^{(3)}) o_{i_3}^{(3)} (1 - o_{i_3}^{(3)}) w_{i_2 i_3}^{(2)} o_{i_2}^{(2)} (1 - o_{i_2}^{(2)}) o_{i_2}^{(1)}. \quad (3.40)$$

Die Gewichtsmodifikation basiert auf der Formel

$$\Delta w_{ij}^{(1)} = -\eta \frac{\partial E}{\partial w_{ij}^{(1)}} = \eta \sum_{i_3=1}^{n_3} (t_{i_3} - o_{i_3}^{(3)}) o_{i_3}^{(3)} (1 - o_{i_3}^{(3)}) w_{i_2 i_3}^{(2)} o_{i_2}^{(2)} (1 - o_{i_2}^{(2)}) p_{i_2}^{(1)}, \quad (3.41)$$

und die Gewichte können insgesamt wie folgt wieder berechnet werden:

$$w_{ij}^{(k)}(1) = w_{ij}^{(k)}(0) + \Delta w_{ij}^{(k)}(1)$$

$$w_{i_1 i_2}^{(1)}(1) = w_{i_1 i_2}^{(1)}(0) + \Delta w_{i_1 i_2}^{(1)}(1)$$

$$w_{i_2 i_3}^{(2)}(1) = w_{i_2 i_3}^{(2)}(0) + \Delta w_{i_2 i_3}^{(2)}(1).$$

3.4.3.4 Wahl des richtigen Abbruchzeitpunkts des Trainings

Im Lauf des Lernprozesses stellt sich irgendwann die Frage, wann das Training abgebrochen werden soll, da keinerlei Verbesserung mehr eintritt oder sogar eine zunehmende Verschlechterung hinsichtlich der Anpassung des Netzes resultiert. In diesem Zusammenhang ist die Problematik des „Overtrainings“¹¹⁸ anzuführen, das bedeutet, dass bestimmte Eingabemuster einfach auswendig gelernt werden und sich daraus letztendlich die optimale Anpassung des Netzes ergibt. Der wesentliche Nachteil dabei besteht darin, dass die erlernten Muster und Zusammenhänge aus der Stichprobe allerdings nicht mehr charakteristisch sind für die Grundgesamtheit und damit das Netz für neue Anwendungen versagt. Im Allgemeinen verliert das künstliche neuronale Netz somit seine Generalisierungsfähigkeit. Aus diesem Grund empfiehlt sich, die Datenmenge in ein *Training Set*, *Training Test Set* und *Validation Test Set* aufzuteilen. Anhand des Training Sets wird das Netz trainiert und die Zusammenhänge erlernt. Die Performance des künstlichen neuronalen Netzes kann dann anhand des Training Test Sets gemessen und beurteilt werden, bevor mit Hilfe

¹¹⁸ Vgl. hierzu und im Folgenden Hecht-Nielsen (1989), S. 115f.

des Validation Test Sets nochmals eine letzte Überprüfung der Netzgüte durchgeführt wird, was quasi als letzte Absicherung angesehen werden kann. Der Grund für die Einführung von Training Set und Training Test Set ist auch jener, dass hiermit das oben beschriebene Problem des Überlernens abgetestet werden kann. Die beiden unterschiedlichen Datenmengen können dann nämlich folgendermaßen genutzt werden:

Unter der Prämisse, dass in beiden Datensätzen die abhängigen Variablen die gleiche Verteilung aufweisen, wird der Trainingsdatensatz wiederum ausschließlich zum Erlernen der vorhandenen Eingabemuster verwendet. Gemäß dem Backpropagation nimmt der Fehler des Training Sets stetig ab. Lässt man das Training Test Set jeweils parallel mit den jeweiligen Gewichten des Training Sets laufen, so nimmt auch hier zunächst der Fehler ab, allerdings wird irgendwann der Punkt erreicht, ab dem die Fehlerfunktion wieder zunimmt, da die erlernten Zusammenhänge aus der Trainingsstichprobe nicht mehr auf das Training Test Set übertragen werden können. In diesem Punkt, in dem das Training Test Set ihren minimalen Fehler hat, sollte das Training abgebrochen werden, da sonst nur noch die Datenmuster des Training Sets auswendig gelernt werden und das Netz damit für Übertragungen auf die Grundgesamtheit ineffizient wird.¹¹⁹

Anhand einer Grafik wird dieser optimale Zeitpunkt des Trainingabbruches nochmals verdeutlicht.

¹¹⁹ Hierzu sei noch angemerkt, dass nicht jedes künstliche neuronale Netz das Problem des Overfittings aufweist. Counterpropagation oder Self-organizing Maps besitzen nicht diesen Nachteil und müssen aus diesem Grund auch kein zusätzliches Training Test Set haben.

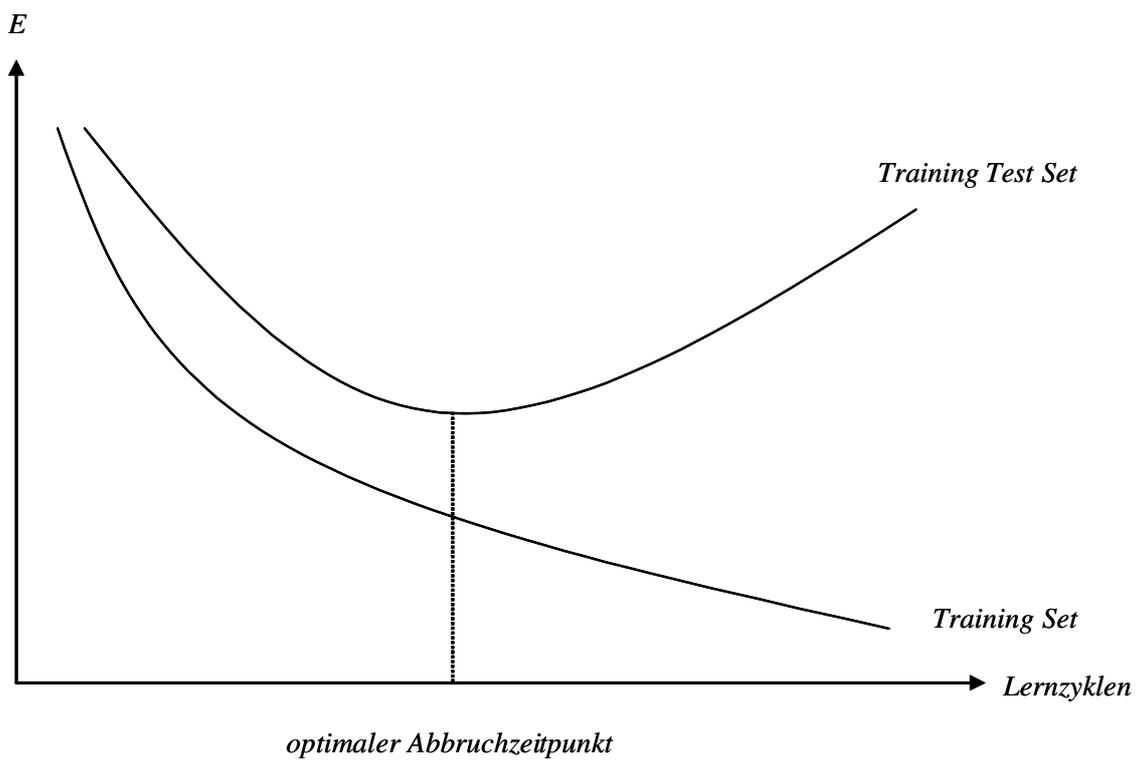


Abbildung 3.13: Optimaler Zeitpunkt des Trainingabbruches

3.5 Kritische Würdigung des Backpropagation-Algorithmus

3.5.1 Lokale Minima

Der Algorithmus des Backpropagation startet, je nach Initialisierung der Gewichte, an einem beliebigen Punkt auf dem Fehlergebirge (vgl. Kapitel 3.4.3.3.2) und seine Aufgabe besteht darin, schrittweise den minimalsten Punkt auf der Fehleroberfläche zu finden. Da die Positionsänderung proportional zur negativen Steigung der Fehlerfunktion an der momentanen Position erfolgt und der Algorithmus lediglich ein lokales Verfahren ist, das keinerlei Informationen über die Fehleroberfläche im Allgemeinen besitzt, kann es passieren, dass ein lokales Minimum fälschlicherweise als globales identifiziert wird (die Steigung hier ist ebenfalls Null) und damit keine Gewichtsanzpassung mehr stattfindet.¹²⁰

Besonders groß ist die Wahrscheinlichkeit in einem solchen lokalen Minimum stecken zu bleiben, wenn die Netztopologie eine große Anzahl an Neuronen aufweist, da dadurch die Anzahl der Verbindungen und damit die anzupassenden Gewichte steigt und implizit mit einer zunehmende Zerklüftung der Fehleroberfläche einhergeht. Dies wiederum verursacht weitere (lokale) Minima und steigert damit die Gefahr, dass der Algorithmus in einem solchen hängen bleibt.

¹²⁰ Vgl. hierzu und im Folgenden Zell (2000), S. 112.

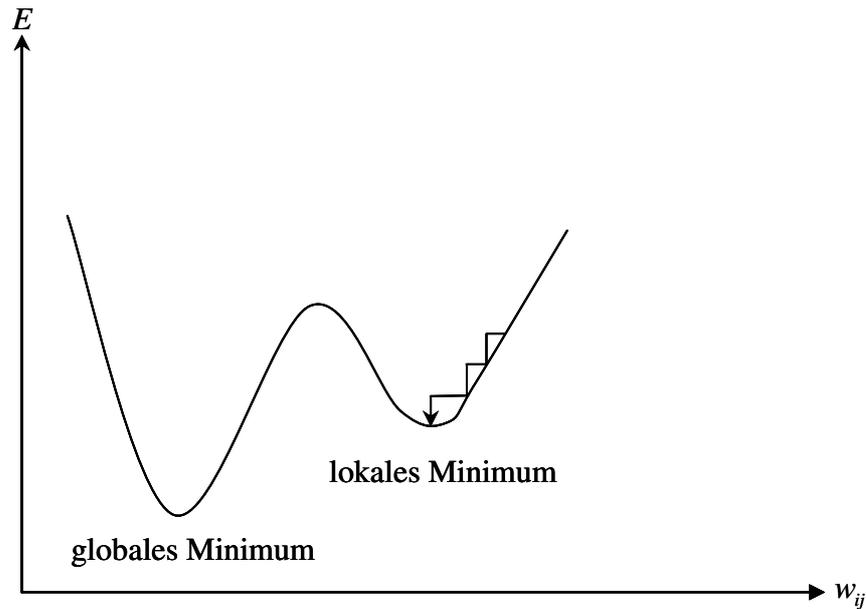


Abbildung 3.14: Lokales Minimum auf der Fehleroberfläche

Zur Lösung dieses Problems, werden in der Literatur mehrere Möglichkeiten angeboten:

Zum einen könnte die Addition von Zufallszahlen zu den bereits erlernten Gewichten ein „Verrauschen“¹²¹ erreicht werden, so dass hierdurch eine Repositionierung auf der Fehlerfunktion erfolgt und von dort aus wiederum versucht wird, das globale Minimum zu finden. Ähnlich funktioniert auch ein anderer Ansatz, bei dem nicht die erlernten Gewichte, sondern bereits den Inputmustern ein Rauschen hinzugefügt wird. Und schließlich soll auch durch Erhöhung von Hidden Neuronen oder sogar ganzen verdeckten Schichten, das Problem in lokalen Minima stecken zu bleiben überwunden werden. Diese Methode ist allerdings mit Vorsicht zu genießen, zumal dadurch die Anzahl der Verbindungen und damit die Gewichte erhöht werden, was in einer weiteren Zerklüftung der Fehleroberfläche führt und die Wahrscheinlichkeit zusätzlicher lokaler Minima erhöht.

¹²¹ Vgl. hierzu und im Folgenden, Poddig (1992), S. 271.

3.5.2 Oszillation in steilen Schluchten

Ein weiteres Problem des Backpropagation zeigt sich dann, wenn die Fehlerfunktion Täler besitzt, die durch steile Schluchten begrenzt werden. In diesem Fall kann das Gradientenabstiegsverfahren für die Gewichtsänderung einen Gradienten liefern, der bewirkt, dass das Minimum übersprungen wird. Da die Steigung auf der gegenüberliegenden Seite ebenfalls sehr groß ist und in die andere Richtung zeigt, erfolgt ein Sprung zurück. Es stellt sich eine Oszillation um das Minimum ein und das Verfahren bleibt wiederum in einer suboptimalen Situation stecken.

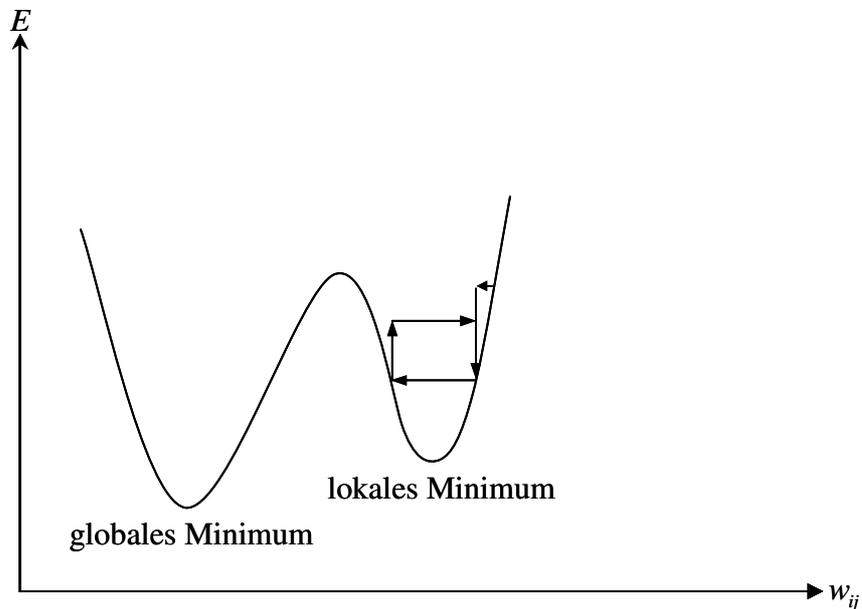


Abbildung 3.15: Oszillation in steilen Schluchten

Um dieses Problem nun zu vermeiden besteht die Möglichkeit des Backpropagation um den sog. „*Momentum-Term*“¹²² zu ergänzen. Das Verfahren wird auch als konjugiertes Gradientenabstiegsverfahren in der Literatur bezeichnet und läuft nach folgenden Maßstäben ab:

Die Gewichtsänderung zum Zeitpunkt t erfolgt nun nicht mehr nur gemäß der Richtung des aktuellen Gradienten, sondern auch unter Berücksichtigung der bereits in $t-1$ vollzogenen Gewichtsänderung. Diese Einbeziehung der zuvor vollzogenen

¹²² Vgl. hierzu und im Folgenden Rumelhart (1986), S. 330; Zell (2000), S. 115f; Köhle (1990), S. 97 und Rigoll (1994), S. 117.

Modifikation wird im Momentum realisiert und kann formal wie folgt dargestellt werden:

$$\Delta w_{ij}(t) = \eta(\delta_j o_i) + \mu \Delta w_{ij}(t-1) \quad (3.42)$$

μ ist hierbei das Momentum und liegt im Intervall $[0;1]$. Wie der Name schon andeutet, kann dieser Wert auch als Erinnerungsfaktor angesehen werden, zumal hierin festgelegt wird, in welchem Ausmaß die Gewichtsänderung des vorausgegangenen Lernzyklus in den aktuellen eingeht und sich damit an den früheren Trainingsdurchlauf erinnert. Konkret bewirkt das Momentum eine Verzögerung der Gewichtsanzpassung, so dass in steilen Schluchten das Minimum nicht einfach übersprungen wird. Um dieses Ziel auch zu erreichen, wird in der Literatur häufig empfohlen, den Momentum-Term zwischen 0,6 und 0,9 zu setzen.

3.5.3 Flache Plateaus

Nicht nur extrem steile Schluchten können zu Schwierigkeiten in der Konvergenz des Algorithmus führen, sondern auch sehr flache Teilpassagen der Fehlerfunktion bergen Probleme, zumal hier die Steigung und damit die Gradienten sehr klein sind und die Gewichtsänderungen dementsprechend gering ausfallen. Die Anzahl der Iterationsschritte, die das Lernverfahren dabei benötigt, wird sehr groß bzw. in extrem flachen Teilstücken kann das Lernsystem generell zum Erliegen kommen.

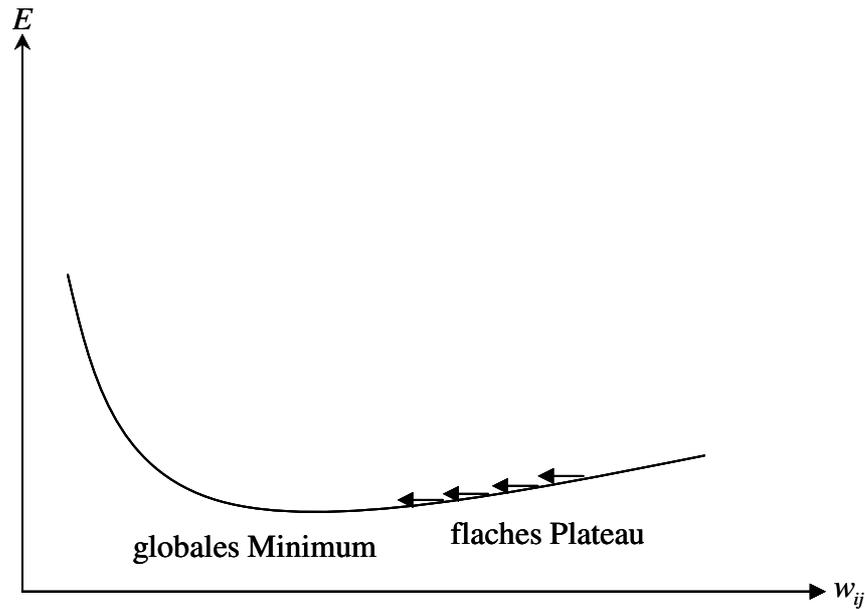


Abbildung 3.16: Flache Plateaus

Auch in diesem Problemfall kann der Momentum-Term wieder als Lösungsmöglichkeit herangezogen werden, da durch geschickte Faktorwahl eine Beschleunigung des Lernverfahrens bewirkt werden kann.

3.5.4 Richtige Wahl des Lernfaktors

Meistens muss die Lernrate η experimentell bestimmt werden, zumal bisher keine einschlägigen Berechnungsweisen für den optimalen Wert dieses Faktors existieren. Dies ist zwar mit einem hohen Zeitaufwand verbunden, allerdings hängt die Performance des Lernverfahrens wesentlich von diesem Parameter ab. Je größer der Wert von η ist, umso größer ist auch Δw_{ij} und umso schneller kann das globale Minimum der Fehlerfunktion gefunden werden. Jedoch muss hierbei auch berücksichtigt werden, dass durch eine hohe Lernrate auch die Gefahr des Überspringens des gesuchten Optimums zunimmt.

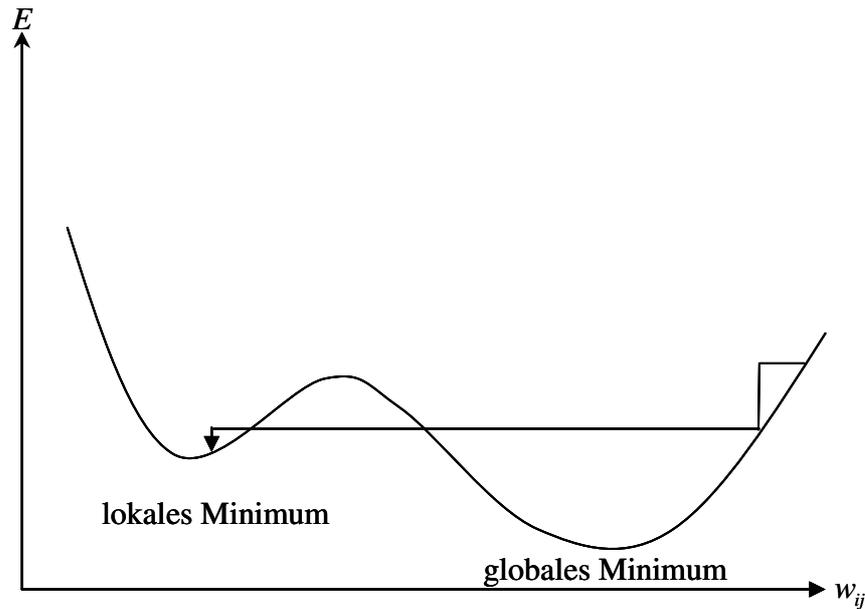


Abbildung 3.17: Überspringen des globalen Minimums bei zu großer Wahl der Lernrate

Wie Abbildung 3.17 zeigt, kann bei einer zu groß gewählten Lernrate das globale Minimum fälschlicherweise übersprungen werden und das Lernverfahren konvergiert dann im suboptimalen lokalen Minimum. Es kann aber nicht nur der eben geschilderte Fall eintreten, sondern auch die Problematik der Oszillation, wenn das Verfahren das Minimum überspringt und auf der anderen Seite einen Gradienten in anderer Richtung vorfindet, so dass das System wieder zurückspringt und damit wieder keine Konvergenz erreicht wird.

Prinzipiell wird häufig ein Kompromiss zwischen möglichst großen Lernschritten (η groß) und wenig oder keiner Oszillation (η klein) gemacht. In verschiedenen experimentellen Versuchen haben sich Lernraten zwischen 0,3 und 0,7 als am besten erwiesen.¹²³

Alternativ dazu bieten sich zu Beginn der Lernphase große Lernraten an, um möglichst schnell voranzukommen und dann den Faktor herabzusetzen, um das globale Minimum nicht versehentlich zu übersehen.¹²⁴

¹²³ Vgl. Köhle (1990), S. 96.

¹²⁴ Auch die gängigen Softwareprogramme bieten automatische Parameteranpassungen an, d. h. während des Lernverfahrens wird der Lernfaktor sukzessive angepasst und optimiert, um eine sehr gute Performance des künstlichen neuronalen Netzes zu erreichen.

Kapitel 4: Prognose des Callvolumens im Call Center zur strategischen Personaleinsatzplanung

Dieses Kapitel wird die eben dargestellten theoretischen Grundlagen künstlicher neuronaler Netze auf die Prognose des Callvolumens in der Praxis übertragen. Dazu werden zunächst die zu prognostizierenden Daten und deren Einflussfaktoren erläutert und identifiziert, bevor es zur Bestimmung der optimalen Netzwerktopologie und –parameter kommt. Im Anschluss daran werden die Ergebnisse analysiert und auf die Bedeutung für die strategische Personaleinsatzplanung übertragen.

Der Modellbildungsprozess kann dabei auch an die Vorgehensweise der Box-Jenkins-Methode, wie sie in der Ökonometrie verwendet wird, angelehnt werden. Im ersten Schritt muss das Data Preprocessing erfolgen, d. h. die zu prognostizierenden Daten müssen identifiziert und aufbereitet werden. Dann beginnt die Phase der Modellspezifikation, in der die optimale Netzwerktopologie ermittelt und festgehalten wird. Der Hauptkern des Modellbildungsprozesses besteht dann in der Schätzung der Parameter, wobei hier auch alternative Ausprägungen der Lernrate und des Momentumterms zu beachten sind, um eine optimale Netzperformance zu erreichen. An diese Phase schließt sich die der Validierung des künstlichen neuronalen Netzes an. Hierunter fallen in erster Linie quantitative Beurteilungskriterien. Erst nach Feststellung einer guten Prognosegüte können die ermittelten Zusammenhänge in die Praxis übertragen und dort implementiert werden.

4.1 Beschreibung der Rahmenbedingungen zur Prognose

Ziel der Prognose soll sein, dass die strategische Personaleinsatzplanung im Call Center verbessert wird und folglich zur Effizienzsteigerung führt. Der Grundgedanke hierbei ist, die grobe Personaleinsatzplanung auf lange Sicht zu optimieren und strategische Entscheidungen, wie Aufstockung oder Reduzierung der Agentenzahl, Gewährung von Urlaubsanträgen oder Einplanung von Weiterbildungsmaßnahmen für die Mitarbeiter, treffen zu können.

Mit Hilfe des folgenden Prognosemodells sollen die für den strategischen Personaleinsatz relevanten Callvolumina möglichst exakt vorhergesagt werden. Die Basis hierfür stellen die historischen Daten dar, die im Call Center durch die Telekommunikationsanlage gesammelt wurden und umfassendes Datenmaterial für die Prognose bieten.

4.2 Identifikation der Einflussparameter

Da sich die Analyse auf reine Inbound Call Centers, die das klassische Feld der Telefonauskunft bedienen, bezieht, sind exogene Schocks im Callvolumen unwahrscheinlicher als in Call Centers, die für Unternehmen oder den staatlichen Sektor Dienstleistungsaufgaben übernehmen. Ein typischer Fall eines extremen externen Einflusses wäre, wenn etwa nach einem Stromausfall (exogener Schock) bei der Hotline des betreffenden Elektrizitätswerkes plötzlich das Gesprächsvolumen signifikant nach oben schnellen würde. Derartige Vorkommnisse sind bei der klassischen Telefonauskunft nicht erkennbar und können daher außer Acht gelassen werden. Dieser Umstand führt zudem dazu, dass in diesen Call Centern die Anrufeingänge viel stabiler sind und aufgezeichnete Vergangenheitsdaten daher als Ausgangspunkt für die Analyse herangezogen werden können.

Um den Personalbedarf zu ermitteln, ist es notwendig, die Anrufeingänge in einem bestimmten Zeitintervall möglichst genau zu bestimmen. Je kleiner das Zeitintervall gewählt wird, umso leichter gestaltet sich dann auch die Personaleinsatzplanung im nächsten Schritt. Es ist demnach empfehlenswert, nicht über eine 60-Minuten-Einheit zu gehen, da sich sonst zeitliche Einflussfaktoren nicht mehr adäquat abbilden lassen. In der vorliegenden Untersuchung werden die Anrufe aus diesem Grund auch in 30-Minuten-Intervallen betrachtet und prognostiziert.

Die entsprechenden Daten können der ACD-Anlage entnommen werden. Wie bereits in Kapitel 2.2 beschrieben, besteht an dieser Schnittstelle von eingehenden Anrufen und interner Verwaltung der Gespräche die Möglichkeit, sämtliche für die weitere

Prognose wichtigen Daten aufzuzeichnen. Dieser Vorteil der Aufzeichnung sämtlicher Daten (relevant oder nicht für weitere Untersuchungen in einem Call Center) kann sich aber in der Praxis rasch in einen Nachteil verwandeln, zumal eine derartige Kommunikationsanalyse eine sehr aufwendige Arbeit darstellt, die zudem umfassende Kenntnisse der Datenstrukturen erfordern. Allerdings zahlt sich diese Investition in der Kapazitätsplanung aus, denn eine mangelnde Prognose aufgrund ungenügender Ausgangsdaten führt zwangsläufig zu einer mangelhaften Planung des Personalbedarfs und dies wiederum macht sich auf der monetären Seite in Form von unnötigen Kosten bemerkbar.

Ein empfehlenswerter Einstieg in die Analyse des Callvolumens in einem Call Center ist, die zu prognostizierenden Daten zunächst deskriptiv zu beschreiben, um so einen ersten Eindruck über das Anrufverhalten zu erlangen.

Hierbei sind unterschiedliche Betrachtungsebenen zu unterscheiden, die jeweils einen anderen Fokus auf die Daten bieten.

Ein erster genereller Überblick über die Calldaten kann durch ein Anruferdiagramm im Jahresverlauf erstellt werden. In unten stehendem Diagramm ist exemplarisch das Jahr 2003 mit den zugehörigen Monatsmittelwerten für die Calleingänge dargestellt.

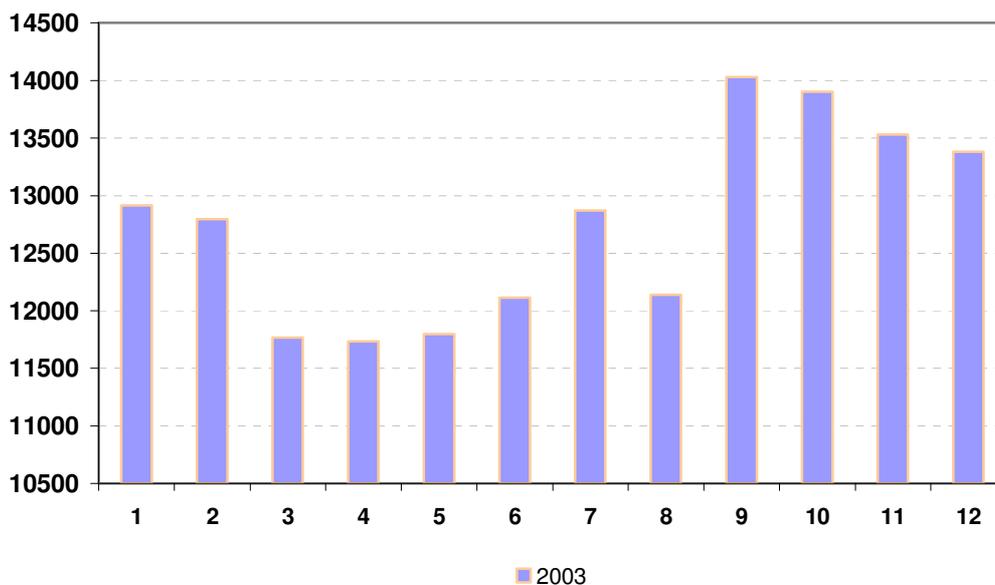


Diagramm 4.1: Jahresübersicht über die Monatsmittelwerte (Calls absolut)

Auf den ersten Blick scheint sich ein vermehrter Calleingang im letzten Drittel des Jahres 2003 zu manifestieren, während sich in den Monaten von März bis Mai eher ein schwächeres Anrufaufkommen abzeichnet. Die Spannweite zwischen dem höchsten (Monat September) und niedrigsten (Monat April) Mittelwert beträgt 2296 Calls. Ob dieser Unterschied allerdings auch signifikant ist, wird in einem späteren Kapitel untersucht.

Die nächst kleinere Ebene im Hinblick auf die Daten wäre die Wochenübersicht. Hier kann wiederum deskriptiv zunächst eine augenscheinliche Abhängigkeit des Callvolumens vom Wochentag abgeleitet werden, wie folgende Abbildung, die beispielhaft das Anrufaufkommen im Oktober 2003 darstellt, zeigt:

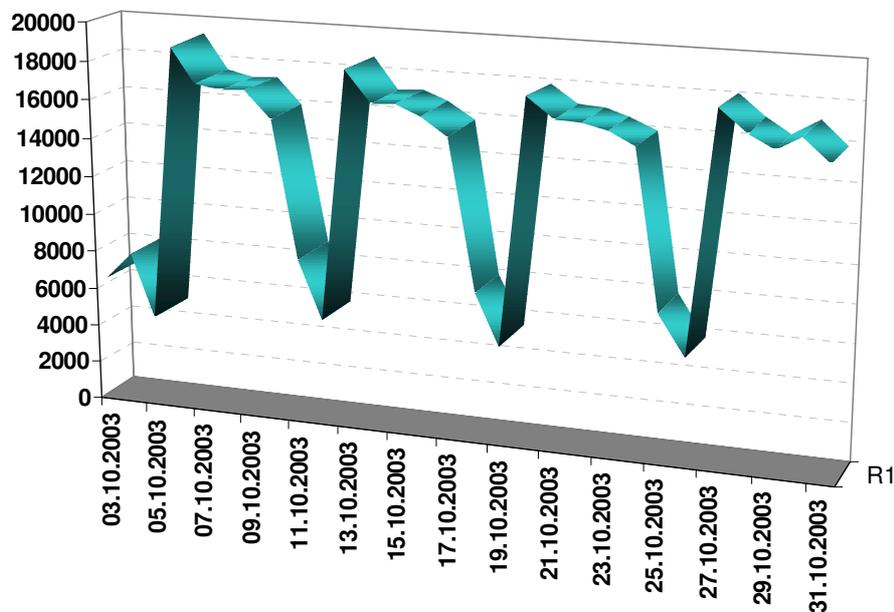


Diagramm 4.2: Wochenüberblick

Wie bereits angedeutet, vermittelt das Diagramm den Eindruck, dass der Wochentag einen wesentlichen Einfluss auf das Callverhalten zu haben scheint. Offensichtlich gehen jeweils zu Wochenbeginn (montags) absolut gesehen die meisten Anfragen ein und fallen zum Wochenende (samstags und sonntags) deutlich ab. Beachtenswert ist auch der Einfluss von Feiertagen (hier der Nationalfeiertag am 3. Oktober). Trotz eines Werktages (2003: Donnerstag) liegt auch hier der Calleingang nur auf dem Niveau von

dem an Wochenenden. Die Signifikanz dieser deskriptiv aufgedeckten Zusammenhänge wird ebenfalls in Kapitel 4.3 noch zu beweisen sein.

Die dritte und damit die, zumindest personaleinsatztechnisch noch sinnvolle Ebene ist die Tagesübersicht. Die Anrufeingänge werden da jeweils auf Stunden oder Halbstundenintervalle zusammengefasst und analysiert. Auch hier können wieder wichtige Erkenntnisse über mögliche Einflussgrößen abgeleitet werden, wie das unten stehende Diagramm zeigt.

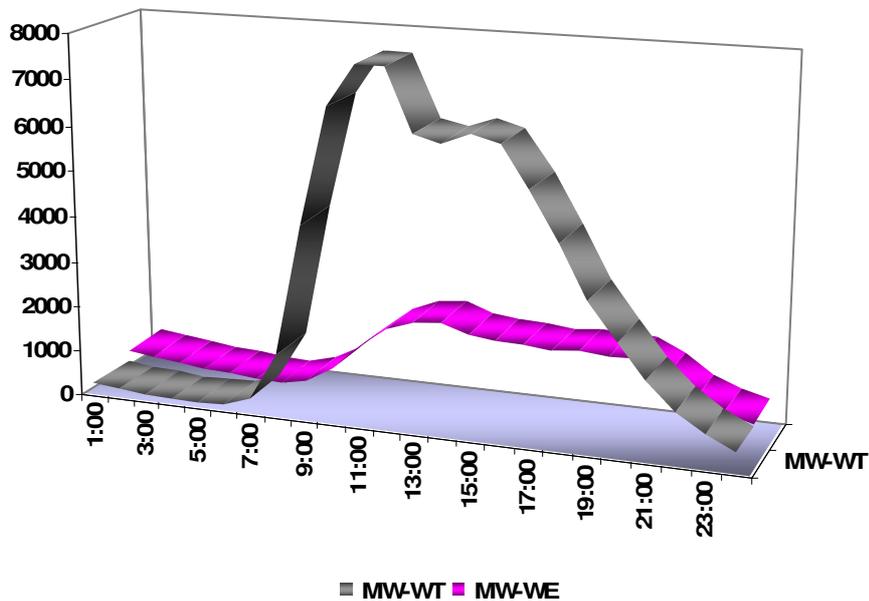


Diagramm 4.3: Tagesübersicht (gemittelte Stundenwerte des Monats September 2004)

Die dargestellten Durchschnittswerte („MW-WT“ steht für den Mittelwert an Werktagen und „MW-WE“ analog für den Mittelwert an Wochenenden, inklusive Feiertagen) der Anrufe über den Monat September geben einen entscheidenden Hinweis auf den Einfluss der Uhrzeit. Die Performance an Werktagen weist dabei stets die gleichen Züge auf. In den Nachtstunden bis cirka sieben Uhr morgens bewegen sich die Anrufeingänge im Call Center auf einem sehr niedrigen Niveau, bevor sie dann in den Vormittagsstunden sukzessive ansteigen, um gegen die Mittagszeit ein erstes Maximum zu erreichen. In diesem Zusammenhang wird auch oft von einem sog.

„Peak Load“¹²⁵ gesprochen, der jeweils das höchste Anrufaufkommen in einem betrachteten Zeitintervall bezeichnet. Im Anschluss an dieses Anrufmaximum schließt sich dann ein kurzzeitiger Rückgang an, bevor die Calls nachmittags gegen 15 Uhr nochmals ein Zwischenpeak erreichen und dann stetig abfallen.

Interessanterweise zeigt sich im direkten Vergleich mit der Callperformance am Wochenende, dass diese eine ähnliche Struktur aufweist, wenn auch auf einem anderen Niveau des Anrufvolumens. Auch an den Wochenenden nimmt die Anzahl der Calls ab den Morgenstunden kontinuierlich zu, bevor sie mittags den Höchststand erreicht und nach einem nur gering ausgeprägten Interimshoch gegen 18 Uhr langsam aber sukzessive abnimmt. Die Verläufe sind also ähnlich, nur zeitlich um etwa eine Stunde versetzt und auf unterschiedlichen Gesamtniveaus.

Somit lassen sich auch in dieser Darstellung zwei Größen ableiten, die das Anrufverhalten bestimmen, nämlich die Uhrzeit und die Unterscheidung zwischen Werktag und Wochenende (bzw. Feiertag). Der Nachweis der Signifikanz wird auch in diesen beiden Fällen in Kapitel 4.3 erbracht.

Zusammenfassend lassen sich beide Einflussgrößen gleichzeitig in einer Übersicht darstellen:

¹²⁵ Vgl. Cleveland/Mayben/Greff (1998), S. 122.

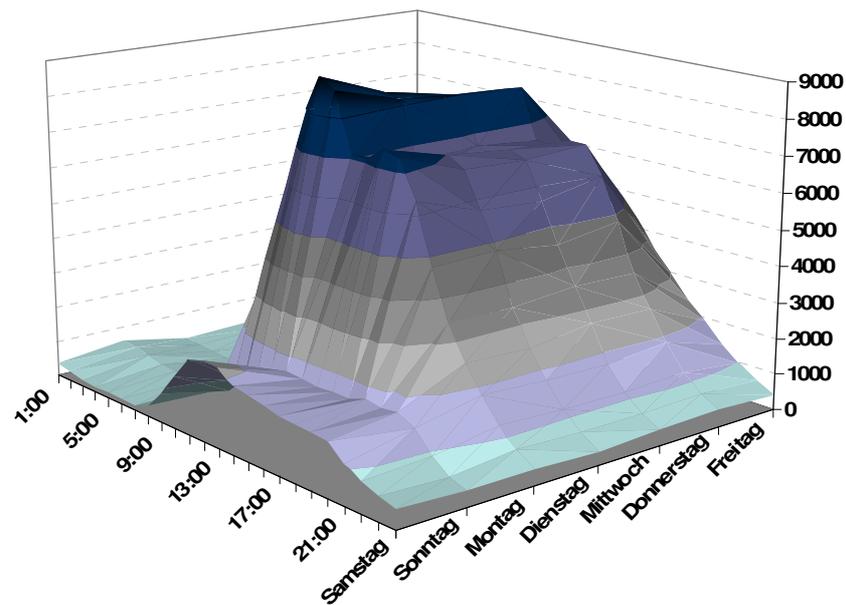


Diagramm 4.4: Darstellung der Einflussgrößen „Wochentag“ und „Uhrzeit“

Montags wird zur Mittagszeit der absolute Anrufpeak erreicht, während sich das Callvolumen sonntags auf minimalsten Niveau bewegt.

Anhand dieser ersten deskriptiven Beschreibung der Calldaten ließen sich nochmals folgende (mögliche) entscheidenden Einflussgrößen ableiten:

- Wochentag
- Uhrzeit
- Feiertag/Wochenende und Werktag
- Monat

Ob diese Zusammenhänge allerdings auch statistisch haltbar sind, wird nun im folgenden Kapitel analysiert, um damit auch eine fundierte Grundlage für die Prognose des Callvolumens zu schaffen.

4.4 Überprüfung der Daten

Im vorherigen Kapitel wurden bereits die wichtigsten Einflussparameter auf das Callvolumen dargestellt. Ob diese nun auch einer statistischen Signifikanzprüfung Stand halten können, wird Aufgabe des folgenden Abschnitts sein. Die Vorgehensweise wird dabei analog zu den eben beschriebenen Datenebenen geschehen, nämlich beginnend von der obersten, und damit größten Ebene (Jahresüberblick), hin zur kleinsten (Tagesüberblick).

Die zur Verfügung stehenden empirischen Daten umfassen den Zeitraum November 2002 bis September 2004, somit gibt es folgende zeitliche Überlappungsbereiche, in denen ein möglicher positiver Zusammenhang zwischen der Komponente „Jahr“ und „Callvolumen“ überhaupt untersucht werden kann:

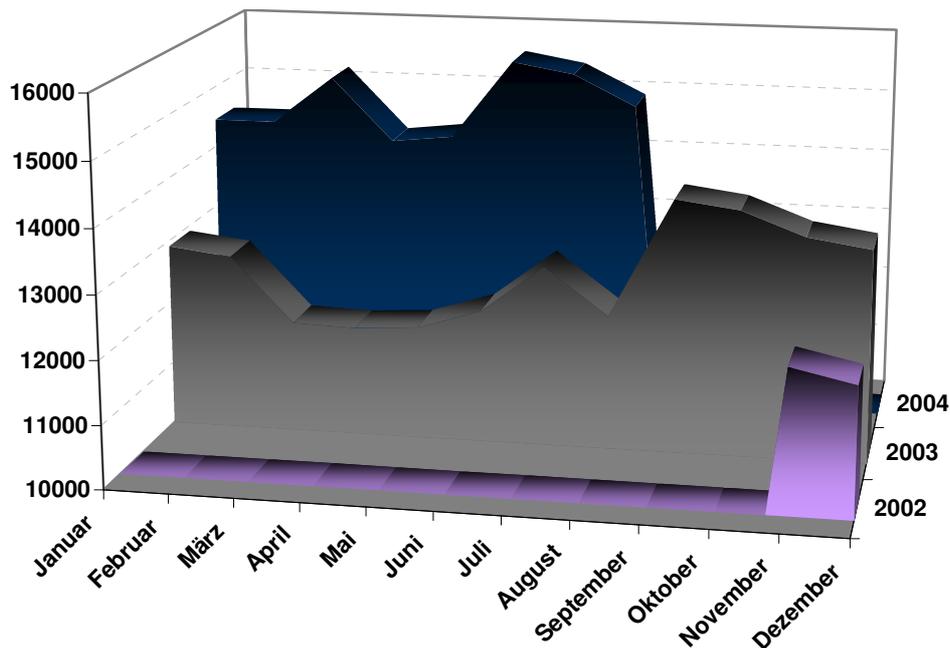


Diagramm 4.5: Jahresvergleich im Callaufkommen

Hier zeigt sich, dass jeweils nur auf Grundlage der Daten von Januar bis September der Jahre 2003 und 2004 und November, Dezember der Jahre 2002 und 2003 ein Vergleich stattfinden kann.

Die hierfür durchgeführte Varianzanalyse kommt zu folgendem Ergebnis:¹²⁶

ANOVA

| Total Calltypes | | | | | |
|-----------------|----------------|-----|-------------|--------|------|
| | Sum of Squares | df | Mean Square | F | Sig. |
| Between Groups | 7,53E+08 | 2 | 376552740,5 | 15,457 | ,000 |
| Within Groups | 1,62E+10 | 665 | 24361078,09 | | |
| Total | 1,70E+10 | 667 | | | |

Abbildung 4.1: Ergebnis der Varianzanalyse für den Jahresvergleich

Die Mittelwertunterschiede der Jahre 2002, 2003 und 2004 sind mit einem Signifikanzniveau von 0% statistisch höchst signifikant¹²⁷ und die Einbeziehung der Variable „Jahr“ als Einflussgröße auf das Callvolumen, ist damit gerechtfertigt. Eine sinnvolle Interpretation dieses nachgewiesenen Einflusses der Variablen „Jahr“ kann lauten, dass hierdurch das Wachstum und damit insbesondere die zunehmende Etablierung des Call Centers am Markt abgebildet werden kann. Diese Variable kann somit auch als Trendvariable angesehen werden.

Der nächste Einflussparameter, den es zu untersuchen gilt, ist die Variable „Monat“. Hierzu wird die abhängige Variable (durchschnittliches Callaufkommen oder „Total Calltypes“) auf das neue Zeitintervall von jeweils einem Monat bezogen und es sollen nun die Durchschnittswerte an Anrufen zwischen den einzelnen Monaten untersucht und verglichen werden. Zu diesem Zweck wird aus dem gesamten Datensatz das Jahr 2003 separiert und zur Analyse herangezogen, wobei wiederum die klassische univariate Varianzanalyse Aufschluss über die Zusammenhänge geben soll. Die deskriptive Beschreibung der Daten aus Diagramm 4.1 ließ bereits einen Zusammenhang vermuten, allerdings zeigt sich in der genaueren Analyse folgendes Bild:

¹²⁶ Vgl. hierzu auch die ausführlichen Outputs der SPSS-Analyse im Anhang.

¹²⁷ Hierbei sei auch darauf hingewiesen, dass der Levene-Test zur Überprüfung der Varianzhomogenität zwar abgelehnt werden muss, weshalb hier auch nicht wie normalerweise üblich ein Signifikanzniveau von 5% als Maßstab angesetzt werden darf, sondern konservativer vorgegangen und damit auf ein Signifikanzniveau von 1% übergegangen werden muss. In diesem Fall ist dies ohnehin unkritisch, da hier der Test bei einem Niveau von 0% abzulehnen ist.

ANOVA

| Total Calltypes | | | | | |
|-----------------|----------------|-----|-------------|-------|------|
| | Sum of Squares | df | Mean Square | F | Sig. |
| Between Groups | 2,34E+08 | 11 | 21295421,94 | 1,011 | ,436 |
| Within Groups | 7,42E+09 | 352 | 21068606,82 | | |
| Total | 7,65E+09 | 363 | | | |

Abbildung 4.2: Ergebnis der Varianzanalyse für den Monatsvergleich

Insgesamt zeigt sich hier, dass die Variable „Monat“ offensichtlich keinen signifikanten Einfluss auf das Anrufverhalten insgesamt hat, da die Ausgangshypothese ($H_0 : \mu_{Calls\ Januar} = \mu_{Calls\ Februar} = K = \mu_{Calls\ Dezember}$) nicht abgelehnt werden kann und die Realität verhält sich damit anders, als zunächst vermutet wurde. In Diagramm 4.1 schien vor allem die Diskrepanz in der Anruflast des Monats August zu den übrigen als sehr groß. Um diesen Aspekt näher zu untersuchen, wird noch zusätzlich ein t-Test angesetzt, wobei jeweils ein paarweiser Vergleich der durchschnittlichen Anrufeingänge durchgeführt wird. Dabei resultiert bei der Überprüfung der Monate August und September, dass die Hypothese ($H_0 : \mu_{Calls\ August} = \mu_{Calls\ September}$) bei einer unterstellten Irrtumswahrscheinlichkeit von 10% nur ganz knapp nicht abgelehnt wird, denn das tatsächliche Signifikanzniveau beträgt 10,8%. Ähnlich verhält es sich mit dem Vergleich der Monate August und Oktober. Die ausführlichen Testergebnisse befinden sich im Anhang. Auf Basis der statistischen Tests müsste also ein Einfluss der Variablen „Monat“ auf die abhängige Variable „Anzahl der Anrufe“ verneint und damit aus dem Ansatz ausgeschlossen werden. Dennoch scheint es vorerst sinnvoll, die Variable nicht komplett aus der weiteren Analyse zu nehmen, da sich die zur Verfügung stehenden und für die Überprüfung sinnvollen Daten nur auf ein einziges Jahr beschränken und darüber hinaus die Teststatistik nur um 0,8% nicht angenommen wird. Die endgültige Entscheidung über den Verbleib der Variablen im Ansatz wird dann also letztlich durch die Sensitivitätsanalyse bei den neuronalen Netzen entschieden.

Als nächstes wird das Merkmal „Tag“ als unabhängige Variable untersucht. In diesem Fall wird die Abhängige („Calls“) wiederum auf ein anderes Zeitintervall bezogen, denn sie geben nun die durchschnittlichen Anrufe pro Tag wieder.

Der Wochenüberblick aus Diagramm 4.2 deutet auf einen signifikanten Zusammenhang hin. Zur Manifestierung der Ausgangsvermutung diene wieder die klassische Varianzanalyse. Obwohl auch hier die wesentliche Annahme der Varianzhomogenität zwischen den Gruppen (hier zwischen den einzelnen Tagen)¹²⁸ abgelehnt werden muss (siehe hierzu Anhang A1.5) und damit wieder ein konservativeres Signifikanzniveau von 1% für die Varianzanalyse anzusetzen ist, kann auch hier die Hypothese, dass die durchschnittliche Anzahl der Calls pro Tag jeweils gleich sind, auf höchst signifikantem Niveau abgelehnt werden:¹²⁹

ANOVA

| Calls | | | | | |
|----------------|----------------|-------|-------------|---------|------|
| | Sum of Squares | df | Mean Square | F | Sig. |
| Between Groups | 39918262 | 6 | 6653043,647 | 476,720 | ,000 |
| Within Groups | 3,69E+08 | 26423 | 13955,867 | | |
| Total | 4,09E+08 | 26429 | | | |

Abbildung 4.3: Ergebnis der Varianzanalyse für den Tagesvergleich

Fraglich ist nun, welche Tage tatsächlich zur Ablehnung der Hypothese führten, denn dieser Aspekt hat später auch erhebliche Bedeutung in der Personaleinsatzplanung. Hier soll nun bereits der Nachweis erbracht werden, um später in Kapitel 5.6 darauf zurückgreifen zu können.

Die Grundlage für die statistische Bewertung der Tagesperformances stellt der t-Test und damit ein jeweiliger Paarvergleich dar. Hiermit soll ermittelt werden, welche Tage sich in ihrer Anruflast signifikant voneinander unterscheiden. Eine Zusammenfassung der Testresultate erfolgt im folgenden Diagramm:

¹²⁸ Die Codierung der Variablen „Tag“ sieht folgendermaßen aus: „1“ = Montag, „2“ = Dienstag, „3“ = Mittwoch, „4“ = Donnerstag, „5“ = Freitag, „6“ = Samstag und „7“ = Sonntag.

¹²⁹ Zu beachten ist hier auch, dass jene Datenfälle aus der Varianzanalyse ausgeschlossen wurden, die an Werktagen einen Feiertag hatten. Dies diente dazu, einer Verzerrung der Daten entgegenzuwirken, denn wie bereits aus der deskriptiven Beschreibung des Wochenüberblicks (Diagramm 4.2) deutlich wurde, beeinflussen Feiertage noch zusätzlich die Callperformance. Der statistische Nachweis wird im nächsten Schritt noch zu erbringen sein.

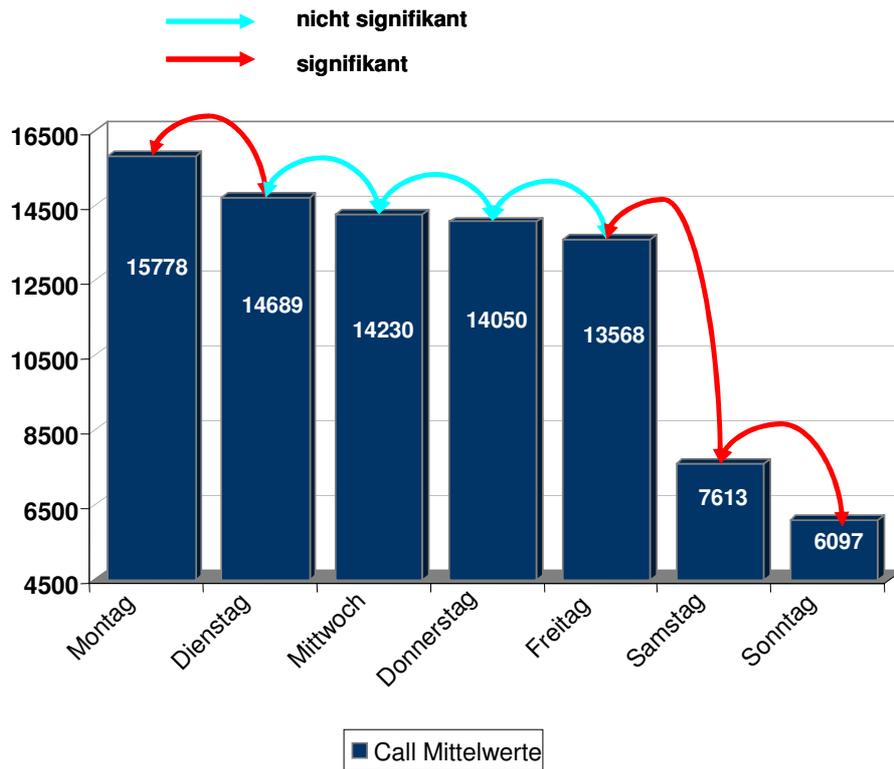


Diagramm 4.6: Paarweiser Vergleich der Tagesperformances

Hier sind nochmals die gerundeten, durchschnittlichen Calls pro Tag aufgelistet. Im paarweisen Vergleich der aufeinander folgenden Wochentage ergibt sich, dass die Anrufe montags signifikant (auf einem Niveau von 5%) verschieden sind zu Sonntag und Dienstag, freitags zu Samstag und samstags zu Sonntag.

Somit haben implizit auch diese Vergleiche zur Ablehnung der Ausgangshypothese für die Varianzanalyse geführt.

In diesem Zusammenhang eröffnet sich aber noch ein zusätzlicher, interessanter Untersuchungsaspekt:

Wie groß ist der Einfluss von Feiertagen bzw. Wochenenden im Vergleich zu normalen Werktagen?

Im Datensatz wurde zu diesem Zweck eine zusätzliche Variable „FE“ eingeführt, die mit „0“ (Werktag) und „1“ (Wochenende oder Feiertag) codiert ist. Auch hierfür ergibt sich ein signifikanter Unterschied im Callaufkommen für normale Werktage und Feiertage bzw. Wochenendtage, wie die SPSS-Ausgabe zeigt:

| | | Independent Samples Test | | | | | | | | |
|-------|-----------------------------|---|------|------------------------------|-----------|-----------------|-----------------|-----------------------|---|--------|
| | | Levene's Test for Equality of Variances | | t-test for Equality of Means | | | | | | |
| | | F | Sig. | t | df | Sig. (2-tailed) | Mean Difference | Std. Error Difference | 95% Confidence Interval of the Difference | |
| | | | | | | | | | Lower | Upper |
| Calls | Equal variances assumed | 12809,829 | ,000 | 54,840 | 27288 | ,000 | 82,942 | 1,512 | 79,978 | 85,907 |
| | Equal variances not assumed | | | 70,457 | 26999,850 | ,000 | 82,942 | 1,177 | 80,635 | 85,250 |

Abbildung 4.4: Ergebnis des Vergleichs von Calls an Werktagen und Feiertagen/Wochenenden

Festzuhalten ist also, dass nicht nur Unterschiede zwischen den einzelnen Wochentagen zu beachten sind, sondern auch eine Differenzierung zwischen Wochentag und Wochenende (bzw. Feiertag) zu treffen ist. Dieser Umstand war zwar bereits aus der deskriptiven Beschreibung der Wochenübersicht abzuleiten, aber nun konnte auch der statistische Beweis dafür erbracht werden.

Denkbar wäre auch, dass die Art des Wochentages, auf den ein Feiertag fällt, ebenfalls einen Einfluss auf das Callverhalten haben könnte. Aus diesem Grund soll nun auch unter diesem Aspekt noch die Callperformance analysiert werden.

Die Testergebnisse können in ausführlicher Darstellung wieder im Anhang A1.6 eingesehen werden, wobei sich die wichtigsten Resultate wie folgt präsentieren:

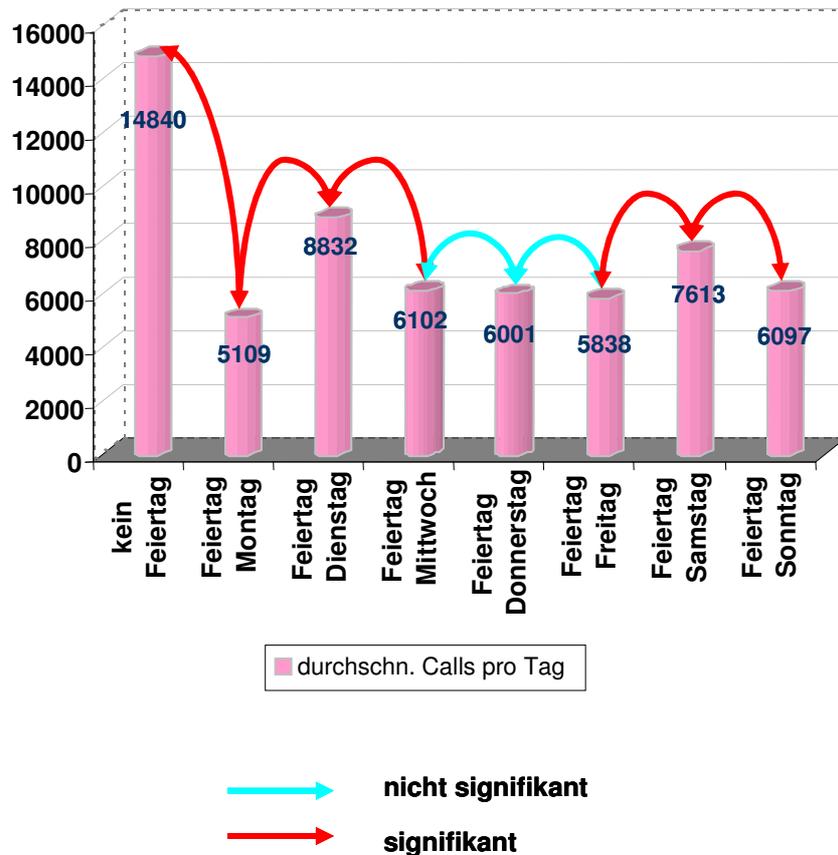


Diagramm 4.7: Ergebnisse des Signifikanztests zum Interaktionseffekt von Feiertag und Wochentag

Damit folgt, dass auch ein Interaktionseffekt zwischen Feiertag und Art des Wochentags besteht, denn der Mittelwertvergleich der durchschnittlichen Calls an normalen Werktagen, d. h. an nicht Feiertagen und an den übrigen Tagen, die einen Feiertag darstellen, bringt als Ergebnis, dass diese durchschnittlichen Anrufe pro Tag eben nicht gleich sind, sondern dass auch durchaus der Wochentag per se eine Rolle im Anrufverhalten spielt. Die entsprechende Tabelle hierzu findet sich im Anhang A1.8.

Das obige Diagramm stellt die Signifikanzresultate überblicksmäßig dar. Jene Zylinder, die durch einen roten Pfeil verbunden sind, deuten auf einen höchst signifikanten, d. h. das Signifikanzniveau liegt unter 1%, Einfluss hin, während die anderen mit einem grünen Pfeil verbundenen Zylinder nicht signifikant sind. Dadurch, dass der Unterschied zwischen Montag und Dienstag, Dienstag und Mittwoch und

Freitag und Samstag statistisch gesehen groß genug ist, findet auch das Merkmal „Intercept“, das künftig diesen Interaktionseffekt beschreiben soll, als unabhängige Variable eine Aufnahmeberechtigung in den Ansatz.

Der letzte Einflussfaktor, der auch in Kapitel 4.1 bereits deskriptiv dargestellt wurde und einen statistisch signifikanten Zusammenhang mit dem Anrufverhalten im Call Center vermuten ließ, ist die Uhrzeit. Der Kurvenverlauf im Diagramm 4.3 zeigt bereits, dass vormittags ein positiver und nachmittags ab 15/16 Uhr ein negativer Zusammenhang zwischen der Uhrzeit und den Anrufen besteht.

Im Datensatz wurde für die Analyse eine Fallauswahl getroffen, d. h. es wurden nur jene Anrufe erfasst, die zwischen acht und zwölf Uhr vormittags eintrafen. Der Grund für diese Aufspaltung des Datensatzes liegt darin, dass sich so die positiven und negativen Zusammenhänge nicht überlagern und damit neutralisieren können.

Statistisch gesehen resultiert dabei folgende Korrelation:

| Correlations | | | |
|---------------------|---------------------|----------------|--------|
| | | Uhrzeitcodiert | Calls |
| Uhrzeitcodiert | Pearson Correlation | 1 | ,496** |
| | Sig. (2-tailed) | . | ,000 |
| | N | 4827 | 4827 |
| Calls | Pearson Correlation | ,496** | 1 |
| | Sig. (2-tailed) | ,000 | . |
| | N | 4827 | 4827 |

** . Correlation is significant at the 0.01 level (2-tailed).

Abbildung 4.5: Korrelation zwischen Anruf und Uhrzeit (vormittags)

Im ersten Teil der Untersuchung zeigt sich nun, dass der positive Einfluss vormittags in Höhe von 0,496 auf höchstem Niveau signifikant ist.

Für den zweiten Teil sieht es ähnlich aus:

Correlations

| | | Uhrzeitcodiert | Calls |
|----------------|---------------------|----------------|---------|
| Uhrzeitcodiert | Pearson Correlation | 1 | -,531** |
| | Sig. (2-tailed) | . | ,000 |
| | N | 4845 | 4845 |
| Calls | Pearson Correlation | -,531** | 1 |
| | Sig. (2-tailed) | ,000 | . |
| | N | 4845 | 4845 |

** . Correlation is significant at the 0.01 level (2-tailed).

Abbildung 4.6: Korrelation zwischen Anruf und Uhrzeit (nachmittags/abends)

Wie erwartet, ist der Einfluss der Uhrzeit negativ auf die Callperformance und aufs Neue höchst signifikant.

Damit ist auch für diese Variable der Beweis für den Einfluss auf das Anrufverhalten in einem Call Center erbracht und wird damit auch in den Ansatz aufgenommen.

Da für den Monat Februar 2004 neben den üblichen Informationen aus der Telefonanlage zudem ein ausführlicher Mediaplan zur Verfügung steht, besteht zumindest für diesen Zeitraum die Möglichkeit, den Einfluss von Marketingaktivitäten zu untersuchen. Für dieses Unterfangen bedarf es allerdings einer kleinen Aufbereitung der Datensätze.

Zunächst werden zwei neue Variablen („TV“ und „Priorität“) eingeführt, wobei „TV“ die Tatsache repräsentiert, ob in der letzten Viertelstunde ein Werbespot gesendet wurde („1“) oder nicht („0“).¹³⁰ Das Merkmal „Priorität“ hingegen gibt die Bedeutung des geschalteten Spots wieder. Berechnet wird sie dabei auf Grundlage des K1-Wertes¹³¹, also der Anzahl der Nutzer pro Ausstrahlung in einem Medium. Dies erscheint deshalb sinnvoll, da zu erwarten ist, dass bei einer Schaltung in einem Medium mit einem hohen K1-Wert dementsprechend auch mehr Kontakte mit

¹³⁰ Der Bezugszeitraum von jeweils 15 Minuten liegt darin begründet, dass die Telefonanlage jeweils die Anzahl der Anrufe im Viertelstundentakt ausgibt. Erfahrungsgemäß erhöht sich in den Minuten unmittelbar nach Schaltung eines Spots (sei es Radio oder TV) die Callzahl sprunghaft und fällt ebenso schnell wieder ab.

¹³¹ Vgl. Schmalen (1992), S. 128. In diesem Zusammenhang wäre natürlich auch das Tausenderkontaktpreis-Kriterium als Bewertungsgrundlage denkbar gewesen, allerdings basiert diese Maßzahl unter anderem auch auf dem K1-Wert und wäre damit mit den gleichen Anwendungsproblemen behaftet, wie der K1-Wert. Die Problematik, die mit dem K1-Wert verbunden ist, wird später noch besprochen.

potentiellen Kunden realisiert werden und damit die Wahrscheinlichkeit für zusätzliche Anrufe im Call Center steigt. Nun ist es allerdings äußerst problematisch für die einzelnen Medien den K1-Wert zu ermitteln, um eine exakte Gewichtung der Schaltungen vorzunehmen. Allerdings ist es intuitiv verständlich, dass der Preis für eine Schaltung in einem Medium hoch mit dem K1-Wert des entsprechenden Mediums korreliert ist. Über den Preis für die jeweilige Marketingmaßnahme (hierunter werden im Folgenden ausschließlich Radio- und Fernsehspots zusammengefasst) kann nun eine Codierung für die Variable „Priorität“ vorgenommen werden. Insgesamt sind im Mediaplan des betrachteten Call Centers sechs Preisklassen zu unterscheiden, die sich in einer Spannweite von 60€ bis 400€ pro Schaltung bewegen. Somit werden hiernach auch sechs Prioritätsstufen abgeleitet, wobei dem teuersten Spot die Priorität „1“ und dem billigsten entsprechend die Priorität „6“ zugeordnet ist.

Sofern für die Marketingaktivitäten ein Einfluss auf die Callperformance nachgewiesen werden kann, wird die Variable „Priorität“ allerdings erst bei der konkreten Prognoseanwendung ihren Eingang finden.

Die Auswirkungen von Marketingmaßnahmen auf den Callverlauf sind nur schwer im Diagramm zu separieren. In nachfolgender Grafik sind die Anrufzahlen in den 15-Minuten-Intervallen, in denen ein Werbespot im TV oder im Radio lief, farblich (roter Punkt) von den übrigen getrennt.

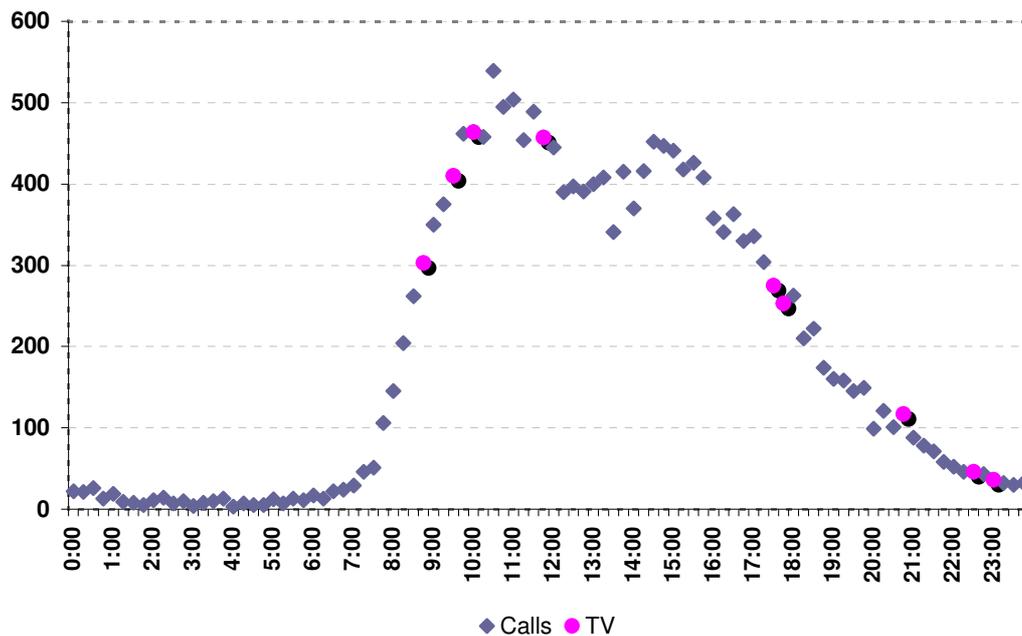


Diagramm 4.8: Anrufzahlen unter Beachtung von Marketingmaßnahmen

Problematisch im Zusammenhang mit der Untersuchung des Einflusses von Werbemaßnahmen sind folgende Aspekte:

Zum einen erschwert der Aufwärtstrend von 7:00 Uhr bis etwa 11:30 Uhr, der hauptsächlich auf dem Einfluss der Uhrzeit beruht, die Effekte von Einzelaktionen auf dem Gebiet der Marketinginstrumente wiederzugeben.

Und zum anderen zeigt sich aufgrund der zeitlich begrenzten Werbewirkung eines Werbespots und dem damit verbundenen Vergessen der Rufnummer kein nachhaltiger Effekt auf das Anrufvolumen. Vielmehr ist der Einfluss innerhalb weniger Minuten nach der Ausstrahlung im Callverhalten schon wieder abgeklungen.

Dennoch soll im Folgenden die statistische Signifikanz des Einflusses auf das Callvolumen untersucht werden, zumal erfolgreiche Marketingmaßnahmen stets erhöhte Callzahlen zur Folge haben sollten.

Um nun dennoch den Zusammenhang zwischen Werbemaßnahmen und Anrufzahlen testen zu können, wird zunächst nur das Zeitintervall zwischen 7:00 und 11:00 Uhr näher betrachtet. Wie bereits erwähnt, sorgt der natürliche Trendanstieg des Callvolumens für Probleme bei der Isolation der Auswirkungen von Werbespots auf die Calls. Aus diesem Grund erscheint es als sinnvoll, die Performance um diesen

zeitlichen Trend zu bereinigen, indem die Differenzen zwischen den aufeinander folgenden Viertelstundenkennzahlen jeweils analysiert werden.

Es gilt also für die neu eingeführte Variable „Differenz“, die allgemein jeweils die Viertelstundenkennzahl repräsentiert:

$$v_{t+1} - v_t \quad \text{mit } t = 00 : 15, \dots, 23 : 45 \text{ Uhr} . \quad (4.1)$$

Mit Hilfe der Variablen „TV“ kann der vorliegende Datensatz dann in zwei Gruppen eingeteilt werden. Nämlich in jene Gruppe von Zeitintervallen, in denen ein Spot geschaltet war („1“) und in jene Gruppen, in denen keinerlei Werbemaßnahmen stattgefunden haben („0“). Ein Vergleich dieser beiden Gruppen soll dann zur Beurteilung der Einflussgröße „Marketingaktivität“ herangezogen werden.

Wenn nun tatsächlich ein signifikanter Zusammenhang besteht, ist zu erwarten, dass in der Gruppe „1“ das Differenzniveau an Anrufen deutlich höher ist als in Gruppe „0“. Auch hier bietet sich ein t-Test für die Mittelwertvergleiche der Differenzen an.

| | | Independent Samples Test | | | | | | | | | |
|-----------|-----------------------------|---|------|------------------------------|---------|-----------------|-----------------|-----------------------|---------|---|--|
| | | Levene's Test for Equality of Variances | | t-test for Equality of Means | | | | | | 95% Confidence Interval of the Difference | |
| | | F | Sig. | t | df | Sig. (2-tailed) | Mean Difference | Std. Error Difference | Lower | Upper | |
| Differenz | Equal variances assumed | ,066 | ,798 | -1,108 | 371 | ,269 | -3,622 | 3,270 | -10,052 | 2,808 | |
| | Equal variances not assumed | | | -1,110 | 128,281 | ,269 | -3,622 | 3,262 | -10,075 | 2,832 | |

Abbildung 4.7: Ergebnis der Analyse von Marketingmaßnahmen

Der entsprechende Output der Analyse zeigt allerdings, dass Werbemaßnahmen das Callvolumen nicht noch zusätzlich erhöhen, denn die Hypothese, dass die Mittelwerte der Calldifferenzen der beiden Gruppen gleich sind, kann nur mit einer Irrtumswahrscheinlichkeit von 26,9% abgelehnt werden, was bedeutet, dass der untersuchte Zusammenhang nicht mehr statistisch signifikant ist. Allerdings fällt auf, dass bei einer weiteren Verengung des betrachteten Zeitraums von 7:00 bis 11:00 Uhr auf 9:00 bis 9:15 Uhr und einer erneuten Durchführung eines t-Tests das Signifikanzniveau sinkt, nämlich auf 18,7% und damit auch die Irrtumswahrscheinlichkeit einer Ablehnung der Ausgangshypothese.

| | | Independent Samples Test | | | | | | | | | | |
|-----------|-----------------------------|---|------|------------------------------|--------|-----------------|-----------------|-----------------------|---------|-------|---|--|
| | | Levene's Test for Equality of Variances | | t-test for Equality of Means | | | | | | | 95% Confidence Interval of the Difference | |
| | | F | Sig. | t | df | Sig. (2-tailed) | Mean Difference | Std. Error Difference | Lower | Upper | | |
| Differenz | Equal variances assumed | 5,548 | ,023 | -1,531 | 42 | ,133 | -12,902 | 8,429 | -29,912 | 4,108 | | |
| | Equal variances not assumed | | | -1,361 | 22,168 | ,187 | -12,902 | 9,483 | -32,559 | 6,756 | | |

Abbildung 4.8: Untersuchung von Marketingmaßnahmen bei verkürztem Betrachtungsintervall

Diese Tatsache kann so interpretiert werden, dass in einem sehr engen Beobachtungsfenster der Einfluss von Marketingaktivitäten tendenziell schon beobachtbar ist, allerdings nicht auf einem statistisch zufrieden stellenden Niveau. Es zeigt sich damit ein relativ rascher „wear-off“-Effekt von Werbemaßnahmen, die lediglich kurzfristige Auswirkungen auf das Callvolumen haben. Langfristige und damit nachhaltige Effekte sind nur mit massiven Werbeausgaben zu realisieren, zumal sich die Call Center-eigene Telefonnummer im Gedächtnis der Zuschauer oder Zuhörer verankern muss und dieser Umstand nur mit regelmäßigen und entsprechend hohen Werbeanstrengungen erreicht werden kann.

Leider kann eine umfassende Analyse des Einflusses von Werbemaßnahmen aus Mangel einer soliden Datenbasis nicht durchgeführt werden, so dass diese Ergebnisse mit einer gewissen Vorsicht zu bewerten sind.

Mit dieser Analyse ist nun auch die Prüfung möglicher Einflussvariablen auf das Callverhalten abgeschlossen und zusammenfassend können folgende unabhängige Variablen festgehalten werden:

- „Jahr“
- „Monat“
- „Tag“
- „Feiertag/Wochenende“
- „Intercept“ (Interaktionseffekt von Feiertag und Wochentag)
- „Uhrzeit“

4.4 Modellspezifikation

Nachdem die Einflussgrößen identifiziert sind, kann im Modellierungsprozess der Callprognose in einem Call Center einen Schritt weiter gegangen werden. Das folgende Kapitel widmet sich ausschließlich der Optimierung des künstlichen neuronalen Netzes, um das Ziel einer möglichst genauen Vorhersage des Anrufvolumens erreichen zu können.

Die hierfür eingesetzte Software ist Clementine 8.5 von SPSS. Der Grund für die Wahl dieses Programms besteht darin, dass es neben dem Feature „Neuronale Netze“ auch eine Schnittstelle für ein effizientes Data Mining bietet und damit ein Baustein für ein Data Warehouse darstellt, das nicht nur Daten sammelt und aufbereitet, sondern auch mit ihnen arbeitet und entsprechende Ableitungen für den Unternehmensprozess möglich macht.

Da die gängigsten Software-Pakete stets den Backpropagation implementiert haben, liegt hierin auch die Tatsache begründet, dass im Theorieteil zu den neuronalen Netzen dieser so ausführlich dargestellt wurde, obwohl für MLPs mittlerweile auch leistungsfähigere Algorithmen (vgl. hierzu die Gradientenabstiegsverfahren zweiter und höherer Ordnung) entwickelt wurden, die den Backpropagation in ihrer Effizienz übertreffen.

4.4.1 Optimierung der Netzwerktopologie

Wie in Kapitel 3 bereits erwähnt wurde, bietet sich zur Prognose von Daten das Netzwerk der Multilayer-Perceptrons (MLP) an. Zumal zudem nichtlineare Zusammenhänge zwischen der abhängigen und den unabhängigen Variablen zu unterstellen sind, ist es empfehlenswert, ein MLP zu implementieren, das mindestens eine verdeckte Schicht aufweist.

Da MLPs mit mehr als einer verdeckten Schicht zu einem erhöhten Lern- und damit Rechenaufwand führt und zudem keine wesentlich besseren Ergebnisse für die vorliegende Problemstellung liefert, besteht das Grundgerüst der Netzwerktopologie

aus einer Eingabeschicht mit sechs *Eingabeunits* (Einflussvariablen), einer *verdeckten Schicht* und einer *Ausgabeschicht* (abhängige Variable).¹³²

Die nachfolgende Grafik soll den prinzipiellen Aufbau der Topologie nochmals kurz darstellen.

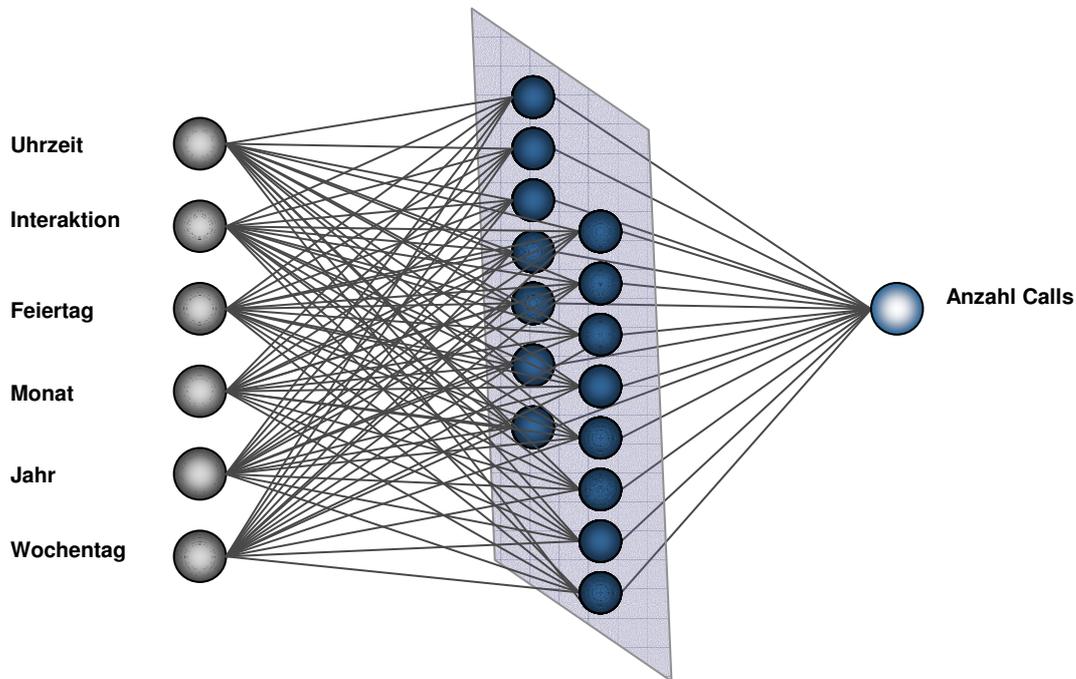


Abbildung 4.9: MLP-Topologie für das vorliegende Prognoseproblem

Was es in einem weiteren Schritt noch zu bestimmen gilt, ist die optimale Anzahl der *Hidden Neuronen*. In der Theorie gibt es unterschiedliche Methoden, um die Netzwerkkonstruktion zu optimieren, wobei grundsätzlich unterschieden werden kann zwischen Verfahren zur *Netzwerkkonstruktion* und Verfahren zur *Netzwerkreduktion*. Erstere Methode startet mit einem zu kleinen Netz mit sehr wenigen (Hidden) Neuronen und erweitert die Topologie sukzessive um neue Units bzw.

¹³² In Clementine besteht die Möglichkeit, unterschiedliche Netzwerktopologien durchlaufen zu lassen und das System bestimmt dann jeweils die optimale Struktur. Um die Anzahl der verdeckten Schichten im vorliegenden Problem bestimmen zu können, wurden dem System stets Netzwerke mit einer und mehreren verdeckten Schichten zur Auswahl gestellt. Die Software führt dann mit den präsentierten Modellspezifikationen Analysen durch und vergleicht die Modelle miteinander. Die beste Topologie wird dann festgehalten und als optimalste Oberfläche ausgegeben. Nach mehrmaliger Analyse der vorliegenden empirischen Daten zeigte sich stets, dass eine Topologie mit drei Schichten (bzw. zwei Stufen) stets ausreicht, um die nichtlinearen Zusammenhänge zwischen den Einflussfaktoren und den zu prognostizierenden Calls äußerst zufrieden stellend abzubilden.

Verbindungsgewichte. Genau den umgekehrten Weg geht die Methode der Netzwerkreduktion. Hierbei wird mit einem zu großen Netz gestartet, um sukzessive die Neuronen zu dezimieren.¹³³ Diese Vorgehensweise wird auch in der Praxis am häufigsten angewendet, so auch in Clementine. Verfahren, die dabei die Netzkomplexität verändern, werden auch als *Pruning*¹³⁴ bezeichnet. In Clementine kann das Neuronen-Pruning im Zuge der Sensitivitätsanalyse durchgeführt werden. Dabei wird zunächst ein Trainingsdurchlauf absolviert und die Ergebnisse abgespeichert. Anschließend wird jeweils ein verdecktes Neuron vom Training ausgeschlossen und die dadurch erhaltenen Ausgabedaten werden wiederum mit den ursprünglichen, abgespeicherten Werten der Ursprungstopologie verglichen. Als Bewertungskriterium kann dann jeweils die Standardabweichung dieser Differenzen zwischen dem Output der Ausgangsarchitektur und dem Output der modifizierten Topologie zu Grunde gelegt werden. Nachdem jedes Neuron des Hidden Layers einmal unterdrückt wurde, können dann die entsprechenden Standardabweichungen miteinander verglichen werden. Große Werte deuten dabei auf wichtige Neuronen hin, kleine auf unbedeutende Units. Im Anschluss daran werden schließlich jene Einheiten eliminiert, die eine kleine Standardabweichung aufweisen, da sie keinen Einfluss auf die Verbesserung der Netzstruktur haben.

Aus Voruntersuchungen¹³⁵ konnte darauf geschlossen werden, dass die Anzahl der Hidden Neuronen zwischen 10 und 20 liegen soll, weshalb sich eine genauere Analyse auf diesen Bereich anbietet. Da die Software keinen Einblick in die genaue Datenstruktur der Verbindungsgewichte ermöglicht und damit die meisten Verfahren der Netzwerkoptimierung nicht anwendbar sind, lehnt sich die folgende Optimierungsstrategie an die des Pruningverfahrens von Clementine. Auch hier sollen Vergleiche zwischen den Outputergebnissen verschiedener Netzarchitekturen miteinander erfolgen.

¹³³ Eine ausführliche Darstellung von Optimierungsverfahren findet sich bei Zimmerer (1997), S. 128f.

¹³⁴ Vgl. Kung (1993), S. 179-182.

¹³⁵ Hierbei wurde mehrmals die Option der „Quick Method“, in der nach einfachen Heuristiken und Daumenregeln schnell eine geeignete Topologie ermittelt wird. Da hierbei keine umfassenden Analysen zur Ermittlung einer optimalen Architektur angelegt werden, bedarf es einer weiteren eingehenderen Untersuchung der Neuronenanzahl der verdeckten Schicht.

Um eine gemeinsame Vergleichsbasis schaffen zu können, werden für die unten stehenden Topologien stets die gleichen Einstellungsparameter angesetzt.

Damit aufgezeigt werden kann, wie schnell eine Architektur im Vergleich zu einer anderen gegen einen minimalen Fehler konvergiert, wurde die Berechnung nach einer gewissen Anzahl durchlaufener Trainingseinheiten (*Zyklen*) gestoppt und das Ergebnis gespeichert. Das Abbruchkriterium bezüglich der Zyklenzahl variiert dabei von eins bis insgesamt 100 Zyklen, wobei zunächst in fünfer Schritten und ab 15 Epochen in 15er Schritten vorwärts gegangen wird. Auf diese Weise ergeben sich also insgesamt 32 verschiedene Netzresultate pro Topologie. Wird für die 32 Ergebnisse die jeweilige Abweichung vom Zielwert berechnet und über diese ein Mittelwert ermittelt, dann resultiert für jede Netzstruktur eine Maßzahl, die wiederum als Vergleichsbasis herangezogen wird. Grafisch können die einzelnen Ergebnisse ebenfalls aufgezeigt werden:

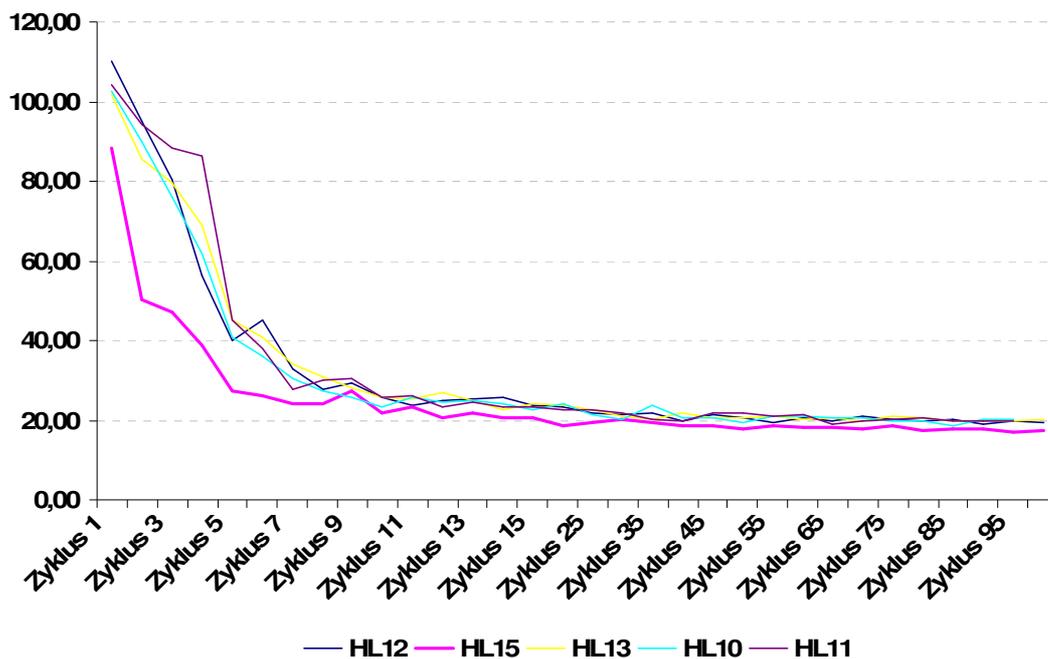


Diagramm 4.9: Vergleich des Netzwerkfehlers bei 15 Hidden Layers mit dem bei 10, 11, 12 und 13 verdeckten Schichten

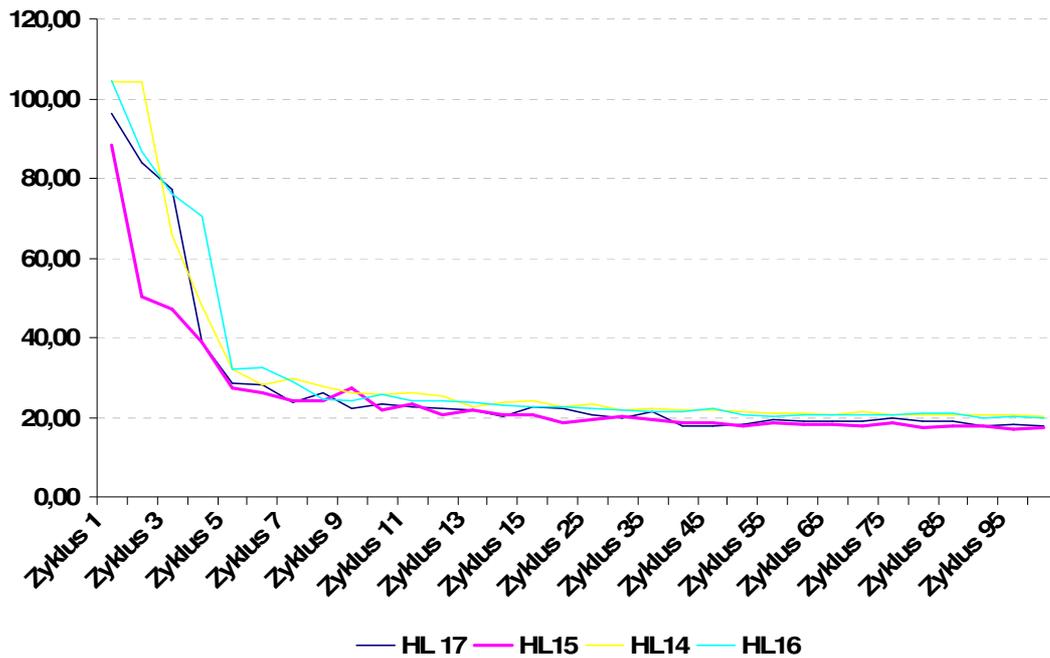


Diagramm 4.10: Vergleich des Netzwerkfehlers bei 15 Hidden Layers mit dem bei 14, 16 und 17 verdeckten Schichten

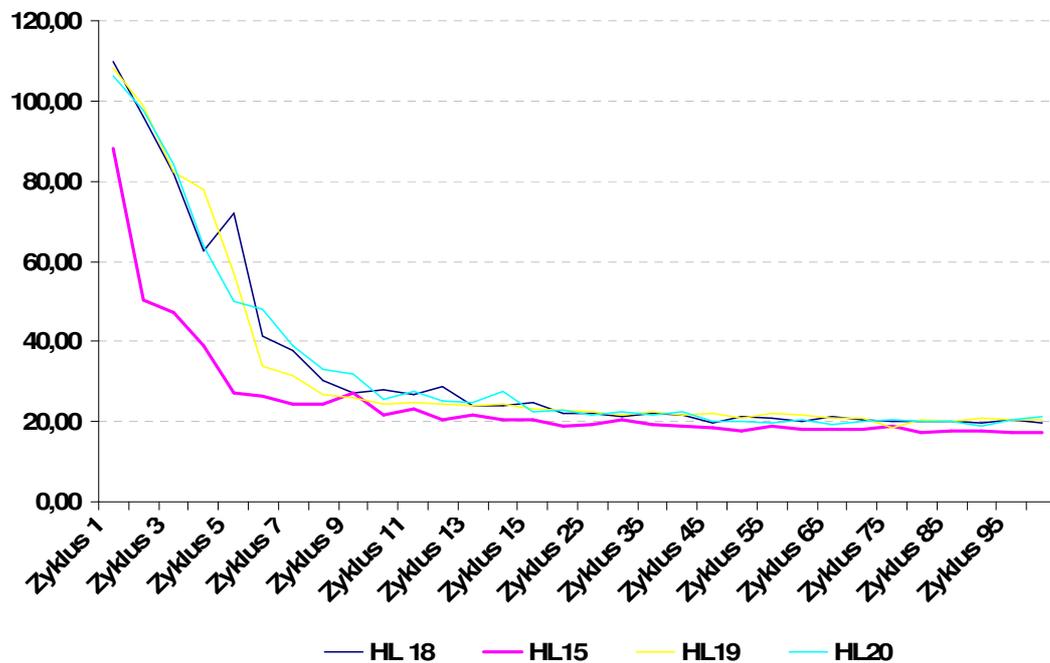


Diagramm 4.11: Vergleich des Netzwerkfehlers bei 15 Hidden Layers mit dem bei 18, 19 und 20 verdeckten Schichten

Die Diagramme 4.9 bis 4.11 zeigen jeweils den durchschnittlichen Fehler des Netzwerks bei unterschiedlicher Anzahl an verdeckten Neuronen (HL steht hierfür für Hidden Layer und die Ziffer für die jeweilige Anzahl der Units) und zu den verschiedenen Zyklen. Es wird deutlich, dass die Architektur mit 15 verdeckten Neuronen (HL15) absolut gesehen stets unter den Fehlerkurven der übrigen verläuft und damit auch schneller gegen ein minimales Fehlerniveau konvergiert. Damit erscheint es sinnvoll zu analysieren, ob dieses niedrigere Fehlerniveau auch signifikant ist.

Die Tests, die im Detail wiederum im Anhang A2.1 eingesehen werden können, zeigen, dass die Struktur mit 15 Hidden Units nicht gegenüber jener mit 14, 16 und 17 auf einem Niveau von 10% signifikant ist, aber gegenüber den Übrigen, d. h. im Vergleich zu diesen liefert das HL15 Netz ein wesentlich geringeren Fehlerdifferenz, was im Umkehrschluss wiederum bedeutet, dass diese Netzwerkarchitektur den anderen zu bevorzugen ist.

Aus diesem Grund wird im Folgenden mit jeweils 15 Neuronen in der verdeckten Schicht weitergearbeitet.

Die endgültige Struktur des MLP weist demnach fünf Inputneuronen, 15 Hidden Neuronen und ein Outputneuron auf.

4.4.2 Optimierung der Netzwerkparameter

Im Theorieteil zu den künstlichen neuronalen Netzen wurden schon verschiedene Parameter angeführt, die für die Netzperformance entscheidend sein können. Darunter fallen insbesondere die Lernrate und der Momentumterm. Beide Parameter beeinflussen die Veränderung der Verbindungsgewichte und tragen dabei entscheidend zur Lernfähigkeit des Netzes bei.

Das Verhalten beider Parameter im System ist dabei unterschiedlich und soll im Folgenden näher erläutert werden.

Zunächst liegt der Fokus auf der Lernrate η . In Clementine wird mit einer dynamischen Lernrate gearbeitet, um hiermit dem Dilemma aus schnellem Erreichen

des globalen Minimums (hohe Lernrate) und dem Überspringen von guten Minimas bei einer zu großen Schrittweite, entgegen zu wirken.

Es besteht also die Möglichkeit, für die Analyse einen *Startwert* sowie zwei weitere Grenzwerte für die Lernrate zu wählen. Der Startwert ist dabei der Ausgangswert beim Start des Trainings, die beiden Grenzwerte bestimmen dann zum einen die niedrigste η_{low} und zum anderen die höchste Lernrate η_{high} , wobei diese Werte jeweils die Spannweite festlegen, in denen sich der tatsächliche Lernwert während der Trainingsphase bewegt. Eta beginnt also beim Startwert und fällt dann auf η_{low} ab, wird wiederum auf η_{high} gesetzt, bevor es wieder auf das Niveau von η_{low} absinkt. Bildlich gestaltet sich das folgendermaßen:

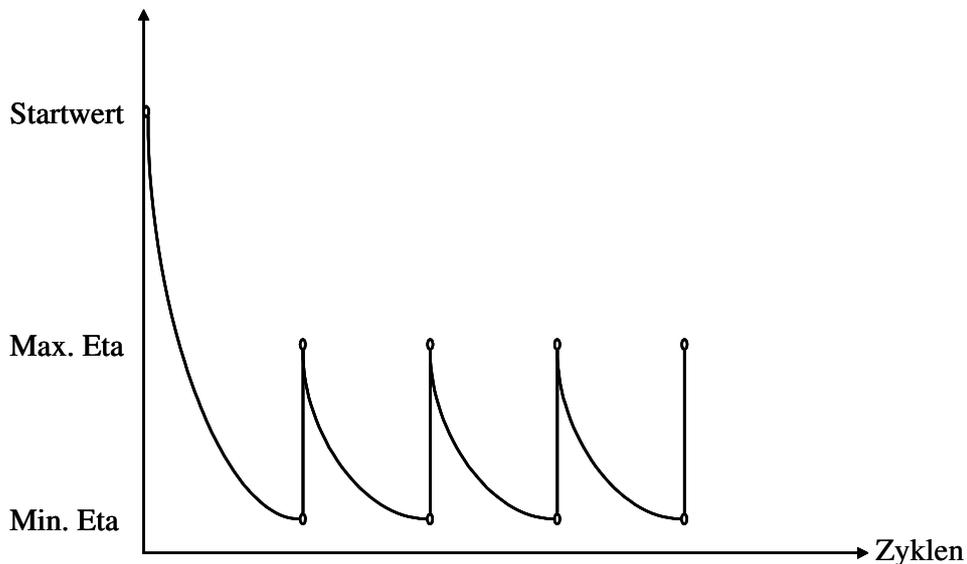


Abbildung 4.10: Verfall der Lernrate während der Trainingsphase (eigene Darstellung in Anlehnung an *Clementine 8.1 Algorithms*)

Der *Verfall* (d) von Eta kann ebenfalls durch den Benutzer festgelegt werden, wobei sich dann die Veränderung von Eta wie folgt berechnet:

$$\eta(t) = \eta(t-1) \cdot \exp\left(\log\left(\frac{\eta_{low}}{\eta_{high}}\right) / d\right). \quad (4.2)$$

Somit kann die Anpassung der Lernrate durch d und damit auch die Variation der Weite der Lernschritte während der Trainingsphase des Netzes exogen beeinflusst werden.

Auch hier haben Voruntersuchungen ergeben, dass das Netz für die empirischen Daten bei Lernraten um 0,6 und 0,65 eine gute Lösung für das Dilemma einer schnellen Konvergenz und einem genauen Absuchen der Fehleroberfläche darstellt. Damit gilt der Wert 0,65 als höchster Wert von Eta, während bei 0,3 der niedrigste Wert für die Lernrate erreicht sein soll und der Verfall d bleibt bei der voreingestellten Größe von 30.¹³⁶ Diese Einstellungen werden dann für die weitere Anwendung der MLPs in Clementine beibehalten.

Der zweite Parameter, der einen wesentlichen Einfluss auf die Veränderung der Verbindungsgewichte hat, ist der Momentumterm. Analog zu den theoretischen Ausführungen in Kapitel 3.5.2 hat sich auch hier aus Voruntersuchungen ergeben, dass ein Wert von 0,9 der beste ist, um den Trainingsprozess zu optimieren.

Nach den ersten Probedurchläufen mit den eben beschriebenen Einstellungen, stellt sich die Frage, ob es noch Verbesserungspotential in der Netzanpassungsfähigkeit gibt. Hierzu soll das Hauptaugenmerk auf der Auffindung einer geeigneten Codierung der Einflussvariablen „Feiertag/Wochenende“ (kurz „FE“) liegen. Dabei wurde für unterschiedliche Kodierungswerte, die zwischen einer „0-1“ bis einer „0-8“ Verschlüsselung lagen, jeweils ein Netztraining durchgeführt und der jeweilige Netzfehler ermittelt. Sollen nun die entsprechenden Ergebnisse in einem Diagramm gegenübergestellt werden, so ergibt sich interessanterweise folgendes Bild:

¹³⁶ Hierbei hat sich somit auch der in der Literatur für die Werte der Lernrate empfohlene Bereich von 0,3 bis 0,9 bestätigt (vgl. hierzu die Ausführungen in Kapitel 3.5.3).

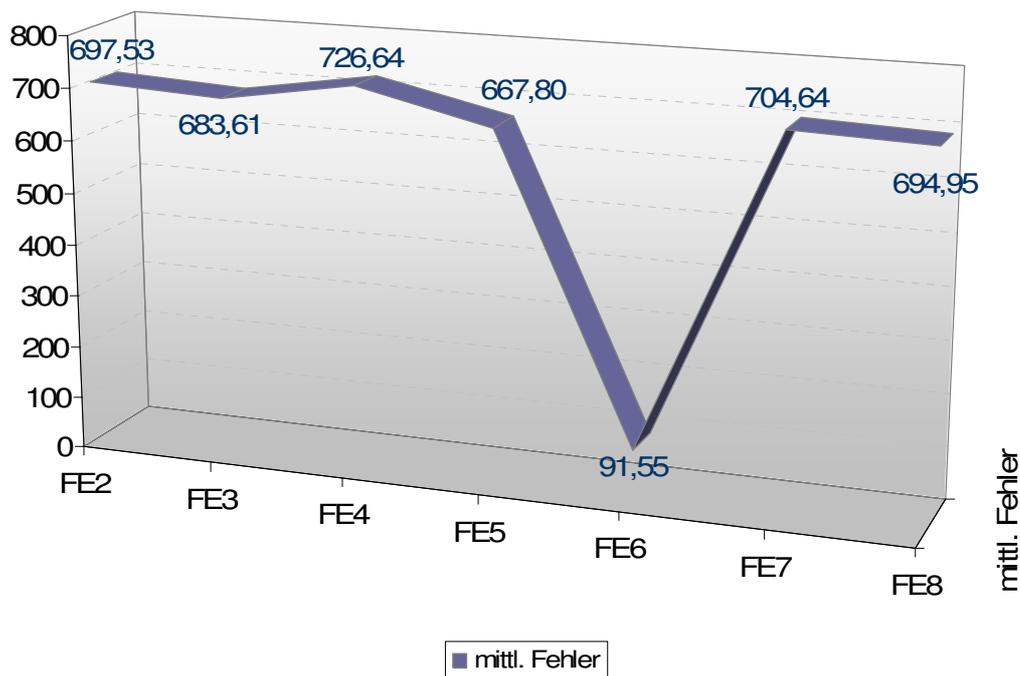


Diagramm 4.12: Mittlerer Netzfehler bei unterschiedlicher Codierung der Variablen „FE“

Es zeigt sich also, dass bei einer „0-6“ Codierung der Variablen „Feiertag/Wochenende“ ein deutlich geringerer Netzfehler resultiert, als bei den übrigen. Führt man hierzu eine Varianzanalyse durch, so zeigt sich, dass dieser Mittelwertunterschied der Fehlerdifferenz nicht nur zufällig, sondern auf einem 5% Niveau signifikant ist (die entsprechenden Auswertungstabellen sind im Anhang A2.2 einzusehen).

Aufgrund dieser Resultate wird die eben untersuchte Einflussgröße neu codiert und für die abschließende Prognose, wie eben dargestellt, eingesetzt.

4.5 Modellschätzung und Überprüfung

Nachdem die Kombination an optimalen Parametereinstellungen gefunden sind, kann die Prognose auf Grundlage der vorliegenden Datenbasis durchgeführt werden.

Es ist allerdings zu beachten, dass die Prognose auf zwei Ebenen abgehalten werden kann. Zum einen kann eine Vorhersage von Calldaten auf Tagesbasis oder auf Stundenbasis durchgeführt werden.

Die Zielsetzung beider Prognosearten ist jeweils eine andere. Bei der Tagesperformance soll eine strategische und damit langfristige Einsatzplanung ermöglicht werden. Dazu werden die prognostizierten Tageswerte herangezogen, um einen ungefähren Überblick über das zu erwartende Callaufkommen zu erhalten.

Die zweite Möglichkeit der Prognose besteht darin, einen Schritt detaillierter vorzugehen und zu versuchen, möglichst genau Stundenprognosen der Anrufe im Call Center zu berechnen. Hierbei könnte in letzter Konsequenz auch eine konkrete Personaleinsatzplanung mit Schichteinteilung der Operatoren abgeleitet werden, ähnlich wie es auch in Kapitel 6 dargestellt wird. In diesem Fall müssten dann die aus den Stundenprognosen resultierenden Ergebnisse in die entsprechende Schichtplanung eingesetzt werden.

In einem ersten Schritt sollen die Ergebnisse des Forecasting für die Tageswerte dargestellt werden.

Entscheidend ist, dass für die Tagesprognose auf die Variable „Uhrzeit“ verzichtet werden kann. Somit stellt sich die Topologie wie folgt dar:

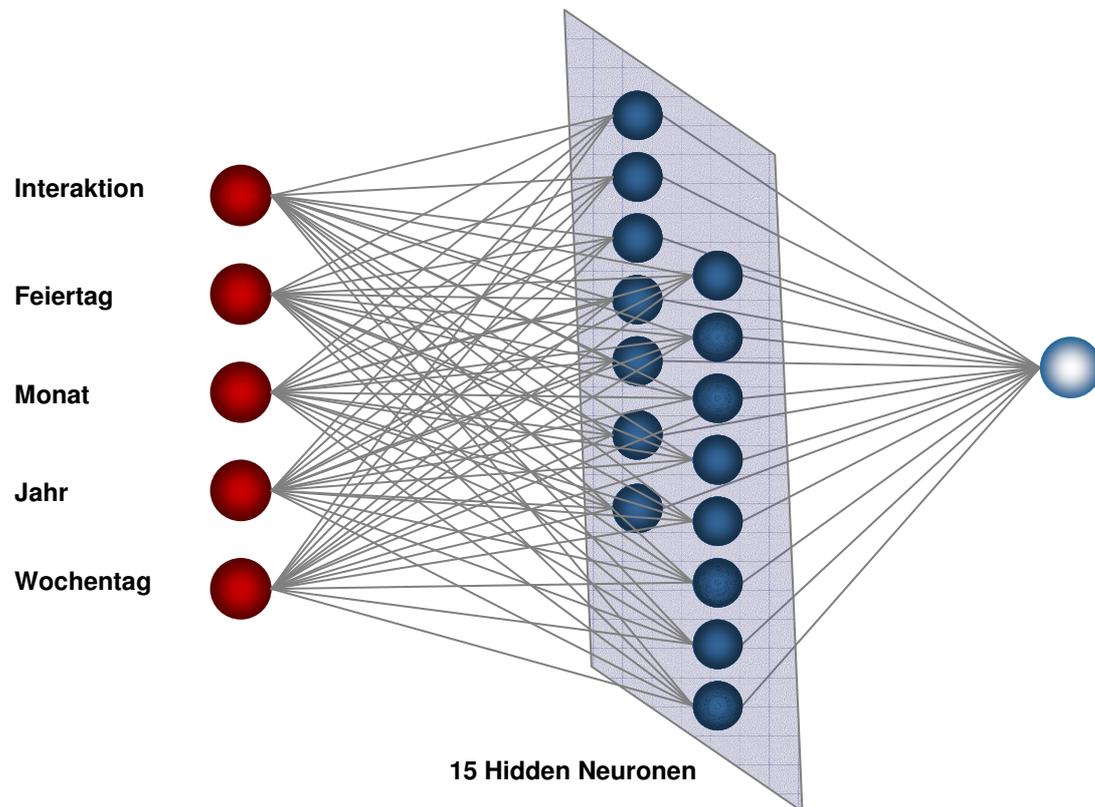


Abbildung 4.11: Netztopologie bei der Prognose der Tagesperformance

Nach dem Training auf Basis der Eingabedaten konnten Ergebnisse aus den neuronalen Netzen abgelesen werden, die in folgendem Diagramm dargestellt sind:

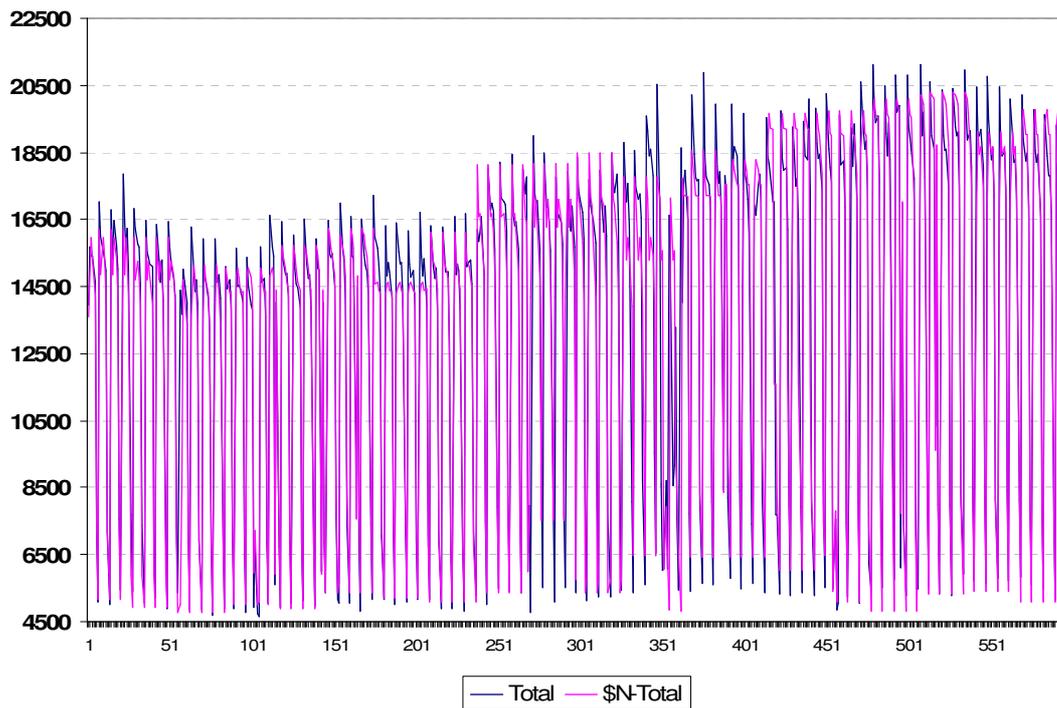


Diagramm 4.13: Überblick über den vollständig prognostizierten Datensatz

Natürlich erlaubt diese Darstellung nur einen ersten Eindruck und lässt noch keine statistisch eindeutigen Aussagen zu.

Dazu sollen nun die *quantitativen Prognosefehlermaße* herangezogen werden, die grundsätzlich auf dem einfachen Prognosefehler

$$e_i = y_i - \hat{y}_i \quad (4.3)$$

basieren, wobei y_i den tatsächlichen zu prognostizierenden Wert und \hat{y}_i (mit $i = 1, \dots, n$) den durch das künstliche neuronale Netz ermittelte Wert darstellt.

Die wichtigsten Gütemaße im Überblick sind:¹³⁷

- Mittlerer Prognosefehler (ME): $ME = \frac{1}{n} \sum_i (y_i - \hat{y}_i)$. (4.4)

¹³⁷ Vgl. hierzu und im Folgenden Anders (1997), S. 80f.; Schwarze (1980), S. 319f. und Rudolph (1998), S. 10f.

- Mittlerer quadrierter Prognosefehler: $MSE = \frac{1}{n} \sum_i (y_i - \hat{y}_i)^2$ (4.5)

bzw. die Quadratwurzel daraus: $RMSE = \sqrt{\frac{1}{n} \sum_i (y_i - \hat{y}_i)^2}$. (4.6)

- Mittlerer absoluter Prognosefehler: $MAE = \frac{1}{n} \sum_i |y_i - \hat{y}_i|$. (4.7)

- Mittlerer prozentualer Prognosefehler: $MPE = \frac{100}{n} \sum_i \frac{y_i - \hat{y}_i}{y_i}$. (4.8)

- Mittlerer absoluter prozentualer Prognosefehler:

$$MAPE = \frac{100}{n} \sum_i \left| \frac{y_i - \hat{y}_i}{y_i} \right|. \quad (4.9)$$

In der Literatur wird meistens der *MSE* (Mean Square Error) bzw. der *RMSE* (Root Mean Square Error) als Bewertungskriterium herangezogen. Dies wird unter anderem damit begründet, dass beide Maße mit der Varianz bzw. der Standardabweichung der Residuen in der Regressionsanalyse vergleichbar sind. Darüber hinaus können sich in diesem Fehlermaß die positiven und negativen Abweichungen nicht saldieren, wie es etwa beim mittleren Fehler *ME* (Mean Error) der Fall ist. Allerdings muss hier beachtet werden, dass sich größere Differenzen deutlich stärker auswirken und damit überbetont werden, was letztlich Probleme bei der Interpretation des Fehlermaßes mit sich bringt.¹³⁸

Der Kritikpunkt am mittleren Fehler *ME* gilt auch für den mittleren prozentualen Prognosefehler *MPE* (Mean Percentage Error), denn auch hier besagt ein Wert von Null nicht unbedingt, dass keinerlei Differenzen zwischen den tatsächlichen und den prognostizierten Werten besteht.

Sofern der Netzoutput nicht eindimensional ist, so wie hier, sondern mehrere Zielvariablen existieren, die zudem noch unterschiedliche Dimensionen aufweisen, empfehlen sich die dimensionslosen Fehlermaße mittlerer prozentualer Fehler *MPE* und mittlerer absoluter prozentualer Fehler *MAPE* (Mean Absolute Percentage Error). Alternativ zu diesen Gütemaßen kann auch der *Korrelationskoeffizient nach Bravais-Pearson* berechnet werden, der darüber hinaus noch den Vorteil hat, dass er ein

¹³⁸ Vgl. Rudolph (1998), S. 11.

normiertes Gütemaß darstellt und den Zusammenhang zwischen den Zielwerten und den vorhergesagten Werten wie folgt berechnet:¹³⁹

$$r = \frac{\sum_i (y_i - \bar{y})(\hat{y}_i - \bar{\hat{y}})}{\sqrt{\sum_i (y_i - \bar{y})^2 (\hat{y}_i - \bar{\hat{y}})^2}} \quad (4.10)$$

mit:

\bar{y} ... Mittelwert der Zielwerte y_i

$\bar{\hat{y}}$: Mittelwert der vorhergesagten Werte \hat{y}_i .

Wie bereits erwähnt, liegt ein entscheidender Vorteil dieses Gütemaßes darin, dass er auf den Bereich von $[-1;+1]$ normiert ist und damit die Interpretierbarkeit und Bewertung der Netzausgabe sehr vereinfacht wird. Ein Wert von $r=0$ würde damit bedeuten, dass kein Zusammenhang zwischen den tatsächlichen und prognostizierten Werten besteht und damit das Ziel der Prognose verfehlt wurde. Das angewandte Modell der künstlichen neuronalen Netze hätte damit versagt und der Ansatz müsste verworfen werden. Das Modell hat auch dann falsch prognostiziert, wenn der Wert des Korrelationskoeffizienten die Ausprägung $r=-1$ annimmt, da dann die tatsächlichen und die erwarteten Werte komplett gegenläufig sind. Bei $r=1$ wäre eine perfekte Anpassung und damit eine absolut fehlerfreie Prognose der Zielwerte gegeben. Somit gilt, je näher der Korrelationskoeffizient bei Eins liegt, umso besser ist der durch das Modell gelieferte Modellansatz. Allerdings ist gerade bei dem Lernkonzept der MLPs ein Korrelationskoeffizient von exakt Eins nicht unproblematisch, da hierbei der Verdacht nahe liegt, dass auch das Rauschen der empirischen Daten mitgelernt wurde und damit die Problematik des Overfitting vorliegen würde. Damit wäre wiederum die Generalisierungsfähigkeit des Netzes nicht gegeben und sobald das MLP auf neue Daten angewendet wird, würden schlechtere Prognosewerte resultieren.

Das letzte Fehlermaß, das in diesem Zusammenhang ermittelt werden soll, ist der *Theilsche Ungleichheitskoeffizient*

¹³⁹ Vgl. Schwarze (1980), S. 337.

$$U = \sqrt{\frac{\sum_i (y_i - \hat{y}_i)^2}{\sum_i y_i^2}}. \quad (4.11)$$

Auch das Theilsche Fehlermaß ist dimensionslos und eignet sich damit wieder sehr gut bei mehrdimensionalen Netzausgaben. Zudem gilt hier, je kleiner der Koeffizient ist, also je näher er bei Null liegt, umso besser ist die Anpassung, oder anders gesprochen, um so „gleicher“ sind die berechneten und tatsächlichen Ausprägungen.

Grafisch kann neben dem Kurvenverlauf im Diagramm 4.13 auch ein Scatterplot erstellt werden, das die Zielwerte mit den Werten, die das MLP ermittelt hat, gegenüberstellt. Sofern sich die Punkte entlang der Winkelhalbierenden zentrieren, deutet dies auf eine sehr gute Anpassung hin, denn die berechneten Werte weichen nur geringfügig von den tatsächlichen Werten ab.

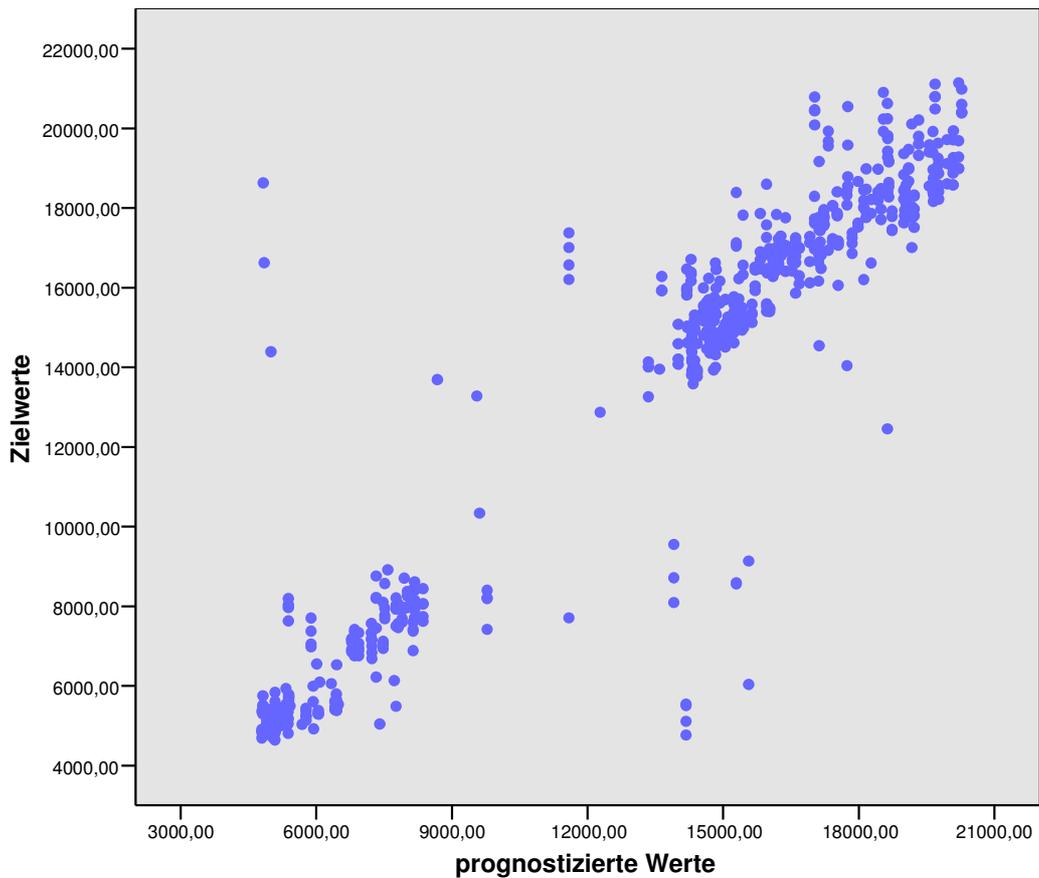


Diagramm 4.14: Scatterplot der Ergebnisse für die Tagesprognose

Wie hier ersichtlich wird, scheint die Anpassung des künstlichen neuronalen Netzes an die realen Daten sehr gut zu sein. Die Punkte zentrieren sich um die Winkelhalbierende und nur vereinzelt existieren Abweichungen davon. Wie präzise die Prognose der Tageswerte an Calls tatsächlich ist, soll anhand der Fehlermaße beurteilt werden.

Hierfür ergaben sich jeweils folgende Werte:

| ME | MAE | MSE | RMSE | MPE | MAPE | Theils U | r |
|-------|--------|-----------|----------|-------|------|----------|--------|
| 67,07 | 901,97 | 2.891.170 | 1.700,34 | -1,26 | 8,10 | 0,0048 | 0,9436 |

Am einfachsten zu bewerten ist Theils U und der Korrelationskoeffizient r. Das inverse Gütemaß liegt dabei mit 0,0048 sehr nahe bei Null und der

Korrelationskoeffizient mit 0,9436 nahe bei Eins. Beides lässt damit die Aussage zu, dass die durch das neuronale Netz berechneten Werte für die Tagesprognose sehr nahe bei den tatsächlichen Werten liegen und damit die Zusammenhänge zwischen den unabhängigen und abhängigen Variablen sehr gut erlernt wurden.

Im Schnitt liegt der prozentuale Fehler dabei bei -1,26%, d. h. tendenziell wird der Zielwert durch das Modell eher unterschätzt und damit ein geringerer Wert berechnet.

Es stellt sich nun noch die Frage, welche Datensätze zu derartigen Abweichungen im Diagramm 4.14 geführt haben. Dazu wurden die Punkte im Scatterplot anhand der unabhängigen Variablen klassifiziert und so versucht, nähere Aufschlüsse über die „Ausreißer“ zu bekommen.

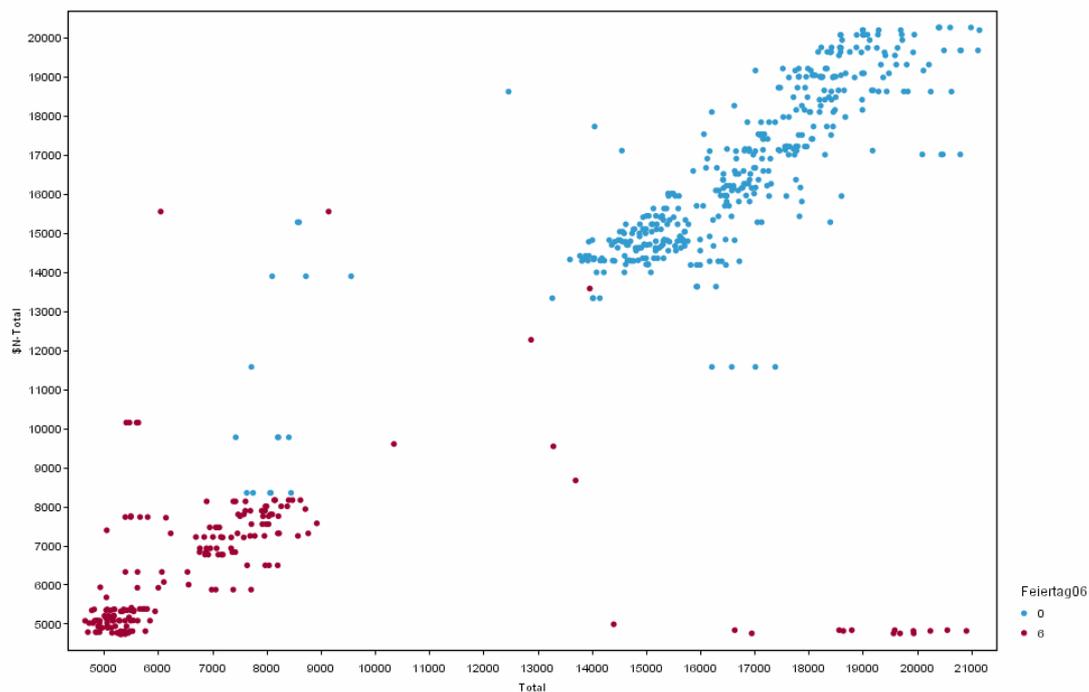


Diagramm 4.15: Scatterplot mit Unterscheidung von Feiertagen und normalen Wochentagen

Werden im Streudiagramm die Datensätze nach Feiertagen/Wochenenden und Werktagen farblich unterschieden, so zeigt sich, dass die größten Differenzen tatsächlich von Werten verursacht werden, die einem Feiertag oder dem Wochenende (rote Punkte) zuzuordnen sind. Demnach scheint das Netz gerade mit diesen Datensätzen gewisse Schwierigkeiten bei der Anpassung zu haben. Werden noch

zusätzlich die Monate in die Differenzierung mit eingeschlossen, so können weitere Rückschlüsse gezogen werden.

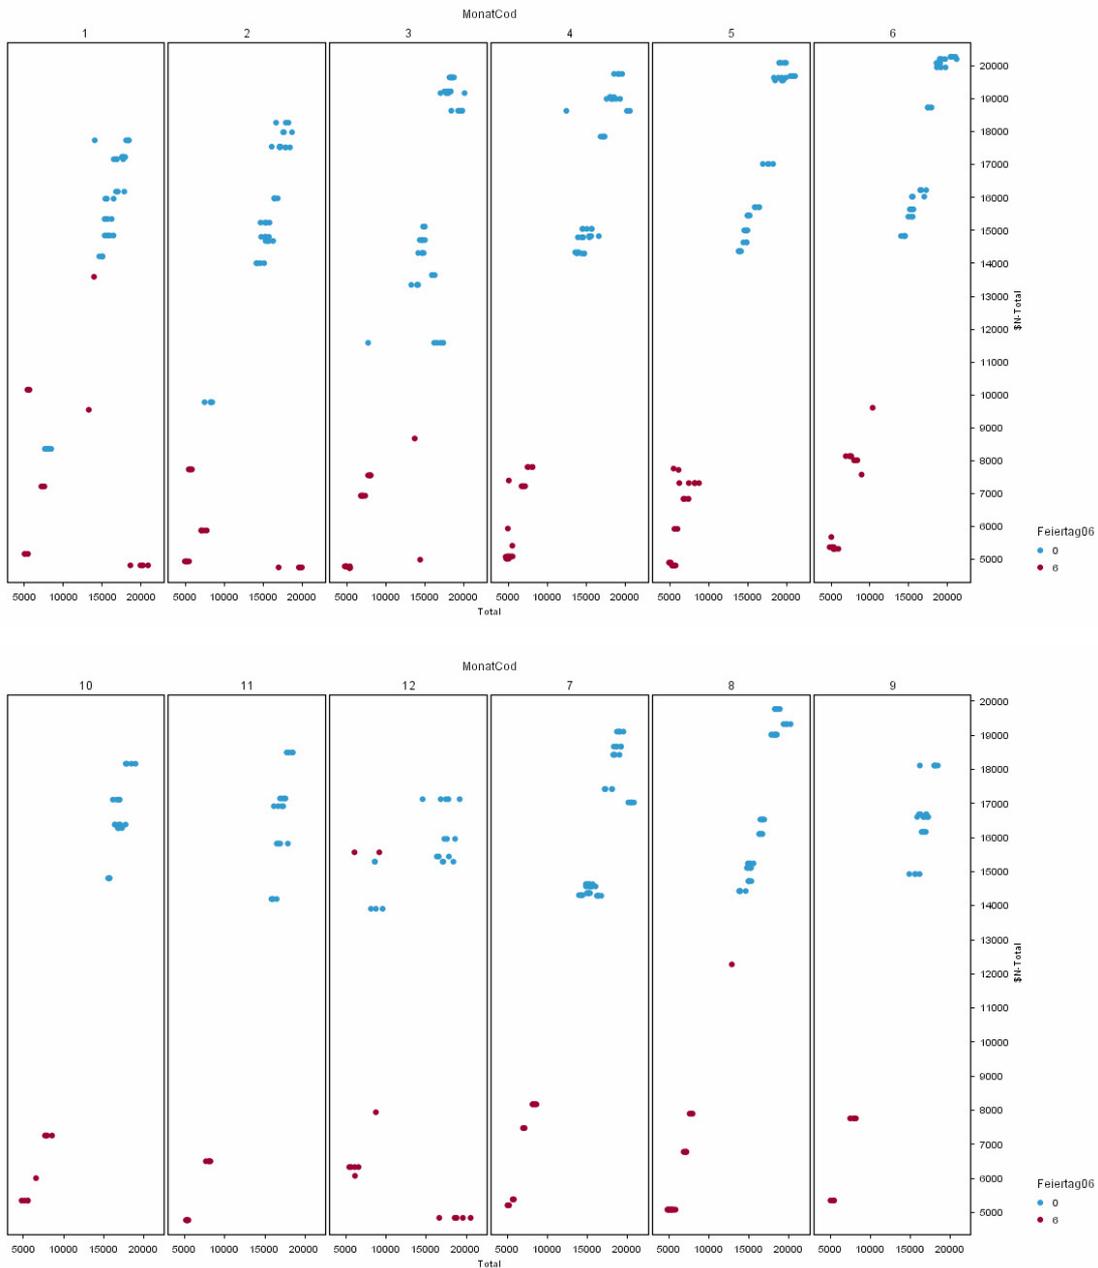


Diagramm 4.16: Scatterplot mit Differenzierung der Daten nach Monat und Feiertagen

Auffällig ist, dass gerade im Monat Dezember und Januar die größten Diskrepanzen (rote Ausreißerpunkte) zwischen den tatsächlichen Calls („Total“) und den prognostizierten Anrufen („\$N-Total“) entstehen. Das künstliche neuronale Netz weist an diesen Tagen also tatsächlich eine niedrigere Anzahl an Anrufen im Call Center

aus, als es in Wirklichkeit der Fall ist. Die Rückverfolgung dieser Daten in den Ursprungsdatensatz zeigt, dass diese schlechte Anpassung hauptsächlich um die Weihnachtszeit und Silvester bzw. Neujahr auftritt. Ein weiterer Blick auf die Wochen- und Tagesverläufe bietet folgende Erklärung:

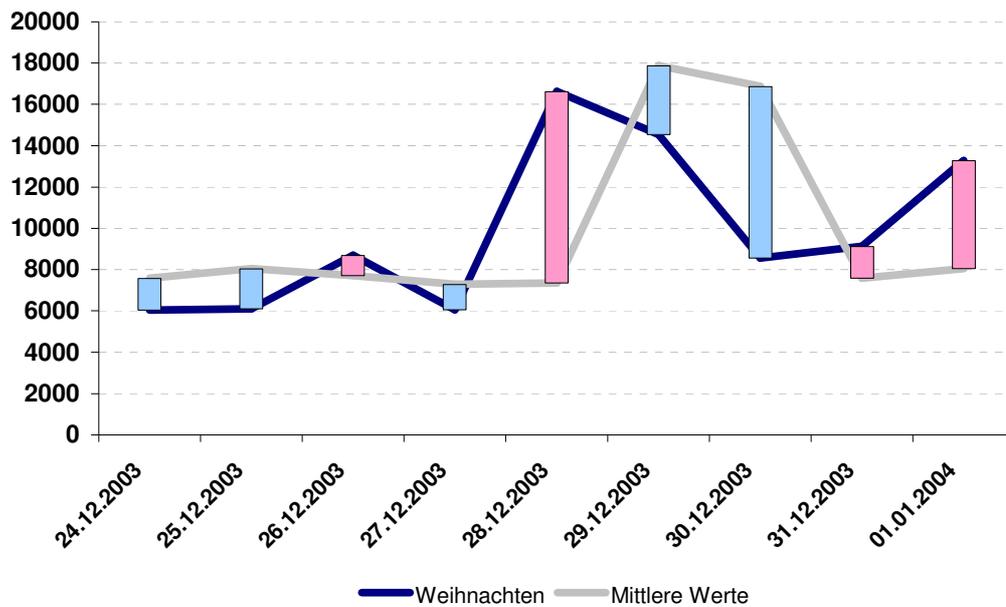


Diagramm 4.17: Einzelvergleich der Callperformance zur Weihnachtszeit mit normalem Callverlauf

Der hier als „Mittlere Werte“ bezeichnete Kurvenverlauf gibt jene Werte an, die bei einem „normalen“ Callverlauf zu erwarten wären. Diese Werte wurden als durchschnittlicher Wert aus jenen Daten berechnet, die nicht in die Weihnachtszeit fallen, wobei zusätzlich der konkrete Wochentag und die Tatsache berücksichtigt werden, ob ein Feiertag vorliegt oder nicht.

Es ist ersichtlich, dass gerade in den Tagen zwischen Weihnachten und Neujahr ein atypisches Callverhalten zu verzeichnen ist. Die entsprechenden positiven und negativen Abweichungen von den erwarteten Callhäufigkeiten wurden jeweils mit roten bzw. blauen Balken gekennzeichnet. Demnach ist am 24./25. Dezember das Anrufvolumen niedriger als im Mittel erwartet, am 28. Dezember steigt die Anzahl der Calls sehr stark an und liegt damit wesentlich höher als an durchschnittlichen Sonntagen (der 28. Dezember 2003 fiel auf einen Sonntag), an den darauf folgenden

Tagen verläuft die Performance wieder eher unterdurchschnittlich. Zu betonen ist auch die relativ starke positive Abweichung der Callzahlen an Silvester und Neujahr.

Da das künstliche neuronale Netz keine Differenzierung zwischen „Weihnachtswoche“ und „nicht Weihnachtswoche“ macht, kann es die Calldaten nur anhand der gegebenen Informationen berechnen. Demnach behandelt es auch die Arbeitstage zwischen Weihnachten und Neujahr als „normale“ Tage und prognostiziert gerade für diese Tage tendenziell einen höheren Callwert.

Somit sind die Abweichungen in den Monaten Dezember und Januar zu erklären. Eigentlich würde sich hier eine weiterführende Analyse und Prognose dieser speziellen Tage anschließen, leider reicht der vorliegende Datensatz mit nur zwei Weihnachtsphasen nicht aus, um eine verlässliche Vorhersage durch das Modell künstlicher Neuronaler Netze berechnen zu lassen.

Als logische Konsequenz schließt sich an die Prognose der Tageswerte die Prognose von Stundenwerten an. Die zentrale Frage hierbei lautet, mit wie vielen Anrufen ist in einem bestimmten Stundenintervall zu rechnen?

Die Netztopologie entspricht der aus Abbildung 4.9 und somit sind jetzt alle zuvor analysierten Einflussvariablen im Modell enthalten.

Die Einstellungsparameter des MLP blieben unverändert und unter diesen Prämissen findet das Netztraining statt. Zu beachten ist lediglich, dass die Anzahl an Calls auf ein 15-Minuten Zeitintervall prognostiziert werden, d. h. jeder einzelne Tag kann in insgesamt 96 Viertelstundenintervalle zerlegt werden und die entsprechenden Anrufzahlen dieser Zeitintervalle über den Tag verteilt sollen nun berechnet werden.

Exemplarisch soll eine kleine Auswahl an Zielwerten und prognostizierten Werten gegenübergestellt werden, um die Anpassungsfähigkeit des künstlichen neuronalen Netzes an das Eingabemuster an Calldaten zunächst grafisch beurteilen zu können.

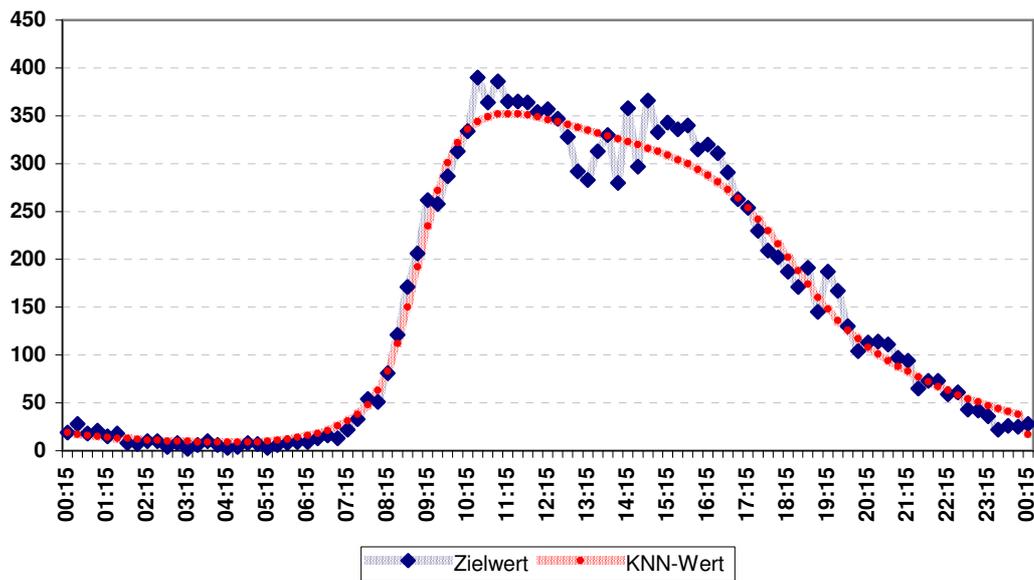


Diagramm 4.18: Vergleich der Ergebnisse der 15 Min-Prognosen

Das Diagramm deutet durch die blaue Linie die tatsächlich eingetroffenen Calls in den einzelnen 15 Minuten-Intervallen an, während die rote Linie jene Werte widerspiegelt, die durch das künstliche neuronale Netz berechnet wurden. Es zeigt sich schon in dieser Darstellung, dass bis auf geringfügige Abweichungen die Callperformance sehr gut abgebildet wurde.

Ein ähnliches Bild wird bei Betrachtung des Scatterplots geboten, in dem wiederum die tatsächlichen Werte mit den berechneten gegenübergestellt sind.

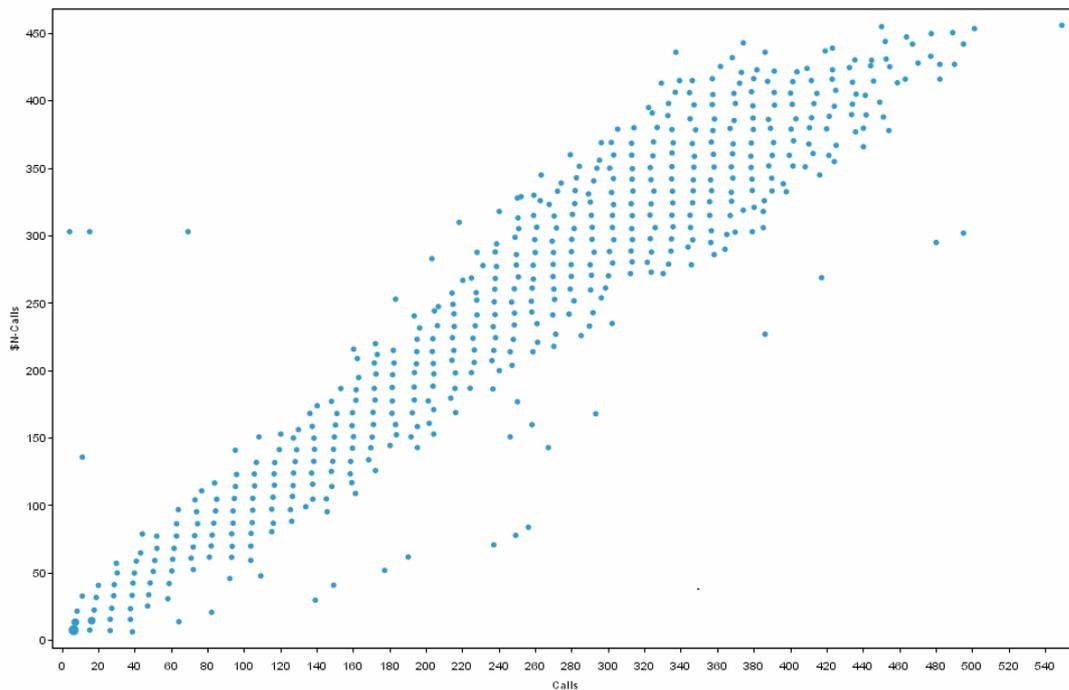


Diagramm 4.19: Scatterplot der Viertelstunde-Prognose

Auch hier zentrieren sich die Punkte entlang der Winkelhalbierenden und deuten damit auf eine relativ gute Prognose der Calls hin.

Eine globalere und damit für das gesamte Netz gültige Beurteilung erlauben wiederum die Prognosefehlermaße, die in diesem Fall wie folgt ausgefallen sind:

| ME | MAE | MSE | RMSE | MPE | MAPE | Theils U | r |
|-------|-------|--------|--------|---------|-------|----------|--------|
| -0,69 | 12,52 | 346,19 | 18,606 | -18,46% | 32,13 | 0,1034 | 0,9887 |

Der Korrelationskoeffizient ist mit 0,9887 äußerst hoch, jedoch ist Theils U (0,1034) ebenfalls etwas größer als in der vorausgegangenen Analyse. Nichts desto trotz ist der Ungleichheitskoeffizient immer noch nahe bei Null und deutet damit analog zum Korrelationskoeffizienten auf einen großen Zusammenhang zwischen den Zielwerten und den durch das künstliche neuronale Netz ermittelten Werten hin.

Der mittlere absolute Fehler MAE liegt bei 12,52 pro Viertelstunde-Intervall und ist im Vergleich zum allgemeinen Callniveau von durchschnittlich 129 Calls¹⁴⁰ in 15 Minuten.

Zudem fällt auf, dass durch das höhere Prognoseniveau nun auch die Problematik der Weihnachtszeit kaum einen negativen Einfluss auf die Vorhersagegüte hat.

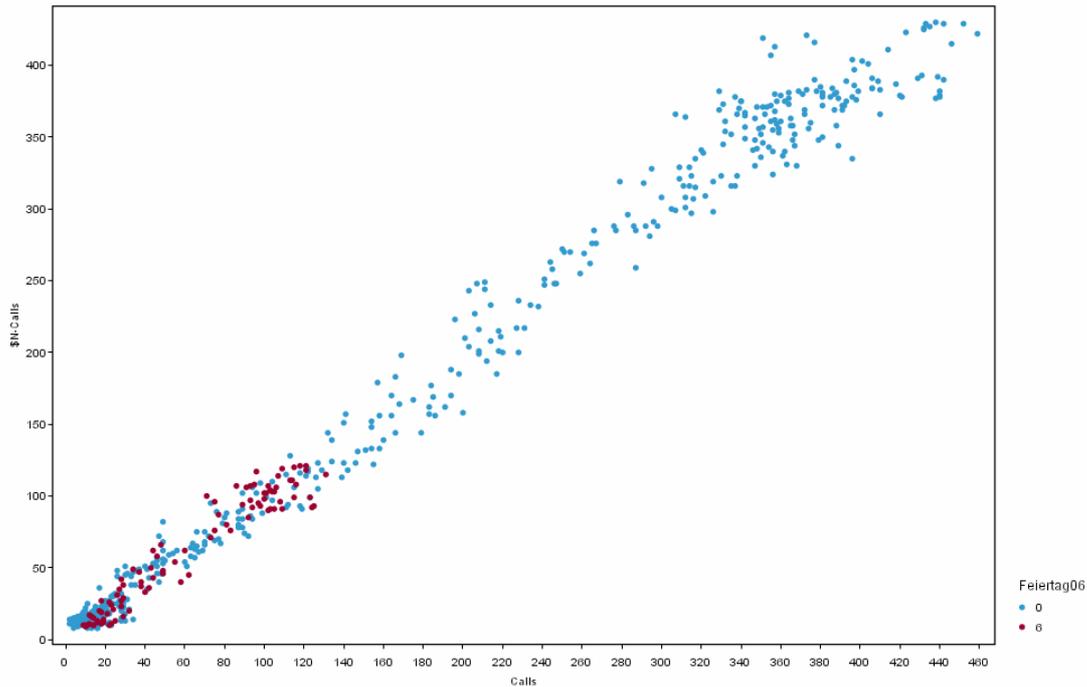


Diagramm 4.20: Scatterplot über die Weihnachtsphase

Das Streudiagramm betrachtet ausschließlich den Monat Dezember und es zeigt sich, dass jetzt auch die Feiertagswerte optimal entlang der Winkelhalbierenden verlaufen.

¹⁴⁰ Hierbei ist zu beachten, dass der Mittelwert von 129 über den gesamten Datensatz berechnet wurde, also auch unter Einschluss der Nachtstunden, in denen das Anrufvolumen deutlich niedriger ist als in den Tagesstunden. Würde diese Diskrepanz zwischen Tages- und Nachtstunden in der Berechnung des durchschnittlichen Callvolumens je Viertelstunde noch berücksichtigt werden, läge der Mittelwert tatsächlich bei 234,7 Anrufen (berechnet auf Grundlage der Datensätze zwischen 8:00 – 18:00 Uhr). Somit relativiert sich auch hier die absolute Abweichung von 12,52 Calls noch weiter.

4.6 Zusammenfassung der empirischen Analyse

Die empirische Analyse der Call Center Daten hat letztendlich gezeigt, dass eine Vielzahl an Einflussfaktoren zu berücksichtigen ist, je nachdem in welchem Zeitintervall die Callprognose stattfinden soll.

Des Weiteren bleibt festzuhalten, dass künstliche neuronale Netze durchaus in der Lage sind, die Problematik einer möglichst exakten Vorhersage der Callvolumina zufrieden stellend zu lösen und damit die strategische Einsatzplanung in Call Centers entscheidend zu unterstützen. Die hohen Korrelationen zwischen den tatsächlichen Callwerten und den durch das jeweilige neuronale Netz berechneten Größen belegen dies in eindrucksvoller Weise. Noch höhere Korrelationen würden ohnehin die Netzperformance wieder in ein schlechteres Licht rücken, zumal dann ein Overfitting vermutet werden müsste und damit eine Übertragung der erlernten Zusammenhänge zwischen der abhängigen Variablen „Calls“ und ihren unabhängigen Einflussfaktoren auf neue Datensätze nicht mehr möglich wäre. Es würden suboptimale Ergebnisse resultieren und das Netzwerk müsste komplett neu trainiert werden.

In der Praxis würden sich an dieses Kapitel strategische Entscheidungen anknüpfen. So wäre das Call Center in der Lage, zu beurteilen, mit wie vielen Calls pro Tag im Durchschnitt in einer bestimmten Woche zu rechnen ist und dies könnte wiederum Grundlage für die Einplanung eines Weiterbildungsworkshops oder Trainingsmaßnahmen für die Agenten sein.

Der erste Teil der Analyse und Optimierung der Personaleinsatzplanung in Call Centers ist damit abgeschlossen. Der strategischen Einsatzplanung folgt die Operative, die Gegenstand der nächsten beiden Hauptkapiteln sein wird.

Kapitel 5: Die Warteschlangentheorie als Grundlage der Personaleinsatzplanung

5.1 Bedeutung der Warteschlangen- und Bedientheorie für Call Centers – Der Warteschlangenprozess

Ganz allgemein gesprochen, kommt die Relevanz von Warteschlangenmodellen immer dann zum Tragen, wenn innerhalb eines bestimmten Zeitraums eine gewisse Zahl von Elementen abzufertigen ist und die Servicestellen aber den Anforderungen nicht nachkommen können.

In diesem Fall bilden sich vor den Servicestellen Schlangen, die auf ihre Abfertigung warten.¹⁴¹

Das gleiche Prinzip gilt auch in allen Call Centern, denn auch hier bilden sich üblicherweise Warteschlangen. Der schematische Ablauf der Prozesse in einem Call Center kann dabei wie folgt beschrieben werden:¹⁴²

Sobald die Nummer des Call Centers angewählt wird, gelangt der Anruf in die Telefonanlage und wird durch das *CSG* („Call Statistic Generator“) registriert und gespeichert. Die Anlage (Software) überprüft in einem ersten Schritt, ob gegebenenfalls eine sog. „*blocking condition*“ greift, d. h. ob der Anruf bestimmte Eigenschaften aufweist, so dass er geblockt wird. Greift keine *blocking condition*, wird der Anruf weitergeleitet. Sofern ein Operator frei ist, wird der Call durchgestellt. Sind allerdings alle Agenten beschäftigt, wird der Anruf automatisch in die *Warteschlange (Queue)* gestellt. Die Verweildauer des Anrufers in der Warteschlange ist dabei zum einen von der eigenen Wartetoleranz¹⁴³ und zum anderen von der Anzahl bereits wartender Anrufer abhängig. Je kürzer die individuelle Wartezeittoleranz ist, umso schneller wird der Kunde den Anruf abbrechen und auflegen. Je mehr Anrufer sich zudem bereits in der Warteschleife

¹⁴¹ Vgl. Ruiz-Palá/Avila-Beloso (1967), S. 3.

¹⁴² Die folgenden Ausführungen sind aus den Prozessen des Call Centers „Infoportal“ abgeleitet.

¹⁴³ Deren Relevanz und auch Problematik im Zusammenhang mit unsichtbaren Warteschleifen wurde bereits in Kapitel 2.3.5 besprochen und kommt auch hier wieder zum Tragen.

befinden, umso länger wird die Verweildauer jedes Einzelnen und umso wahrscheinlicher wiederum wird der Abbruch des Anrufs.

Die Anrufer in der Warteschlange werden prinzipiell nach dem „*First In First Out*“ (FIFO) Prinzip abgearbeitet und demnach dem nächsten frei werdenden Operator präsentiert.

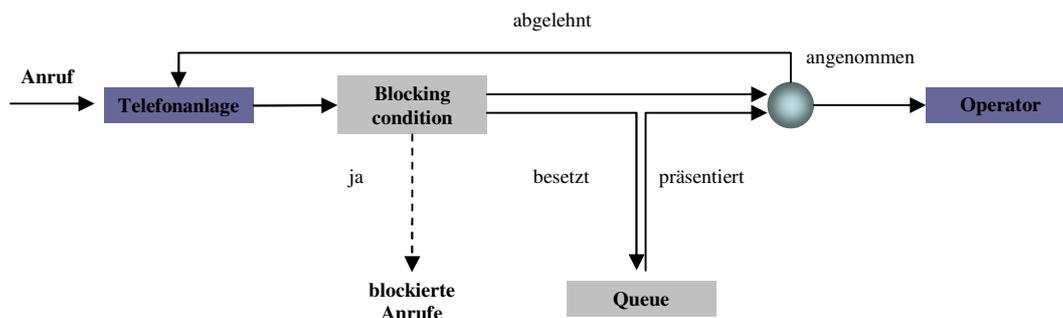


Abbildung 5.1: Anrufprozess in einem Call Center

Den verschiedenen Stationen im Ablaufprozess eines Call Centers entsprechend werden auch verschiedene Zeiten unterschieden. Die Zeitspanne zwischen dem Anrufeingang beim Operator bis zu dessen Annahme, wird als „*accepting time*“ bezeichnet. Die „*holding time*“ beschreibt die gesamte Dauer zwischen der Annahme des Calls durch den Agenten bis zur Freigabe. Die *holding time* darf allerdings nicht mit der reinen Gesprächszeit („*conversation time*“) gleichgesetzt werden, zumal diese tatsächlich nur die Zeit umfasst, in der der Operator mit dem Anrufer letztendlich auch spricht. Oftmals wird ein Anruf auch auf „*hold*“ gesetzt, damit der Operator externe Informationen von entsprechenden Datenbanken abrufen kann, um diese dann an den Kunden weiterzugeben.

In manchen Call Centern wird häufig auch eine sog. „*post call time*“ eingeplant, d. h. nachdem ein Agent einen Anruf bearbeitet hat, wird sein Status im System nicht wieder sofort auf „frei“ gesetzt, sondern es wird ihm noch eine gewisse Zeit zugestanden, um seine Abfragemasken in der Software wieder auf Null zu setzen, um dann wieder für einen neuen Anruf bereit zu sein.

5.2 Eigenschaften und Kenngrößen von Warteschlangenmodellen

Die Darstellung des Anrufprozesses aus Sicht eines einzelnen Kunden (Abbildung 5.1) kann auch auf das Gesamtsystem übertragen werden, d. h. aus einer übergeordneten Sicht des Call Centers können die einzelnen Anrufprozesse folgendermaßen zusammengefasst werden:

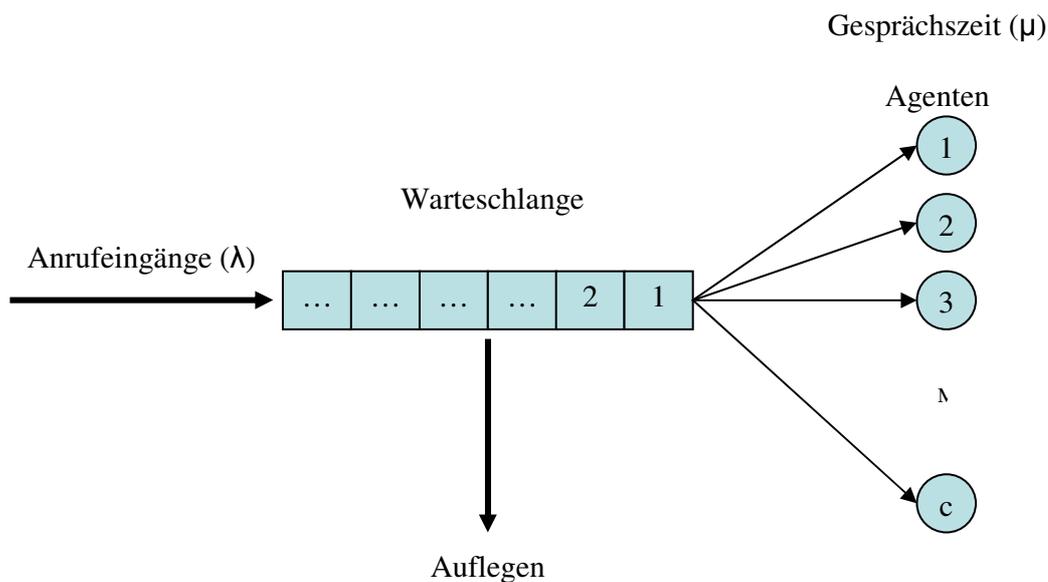


Abbildung 5.3: Schematische Modellierung des Wartesystems in einem Call Center (in Anlehnung an Helber (2005), S. 9)

Die Anrufeingänge treffen also im Call Center ein und nehmen eine bestimmte Warteposition in der Warteschlange an, sofern alle c Agenten mit anderen Kunden beschäftigt sind. Von der Geduld der einzelnen Kunden hängt es ab, ob sie in der Warteschleife ausharren, bis sie zu einem freien Operator weitergeleitet werden, oder ob sie vorzeitig auflegen und damit aus dem System ausscheiden, ohne einen Service in Anspruch genommen zu haben.

Aus obiger Grafik ist schon ersichtlich, dass die Bestimmungsparameter für die Länge der Warteschlange und damit auch für die Dauer des Aufenthalts in der Warteposition, die beiden Größen Anzahl der Anrufeingänge in einem bestimmten Zeitraum (λ), der Anzahl der Agenten (c) und der Servicezeit (μ), die die einzelnen

Agenten zur Bearbeitung der Calls benötigen, sind. Diese Einflussgrößen bedürfen einer genaueren Betrachtung, zumal deren Ausprägungen letztendlich auch auf das gesamte System Auswirkungen haben.

Hierbei ist noch anzumerken, dass die folgenden Ausführungen speziell auf die Modellannahmen der Warteschlangentheorie für Call Centers zugeschnitten sind und sie sollen die theoretische Grundlage für die empirischen Ausführungen in Kapitel 6 bilden.

5.2.1 Der Ankunftsprozess

Der Ankunftsprozess bildet die Anzahl der Telefonanrufe ab, die in einem bestimmten Zeitintervall im Call Center eintreffen. Hier können unterschiedliche Detaillierungsgrade unterschieden werden, denn es wäre denkbar, die Anzahl pro Tag, pro Stunde oder pro Viertelstunde zu erfassen und zu analysieren. Üblich ist eine Erfassung je 15 Minuten.

Die Kenngröße, die den Ankunftsprozess jeweils spezifiziert, ist die Ankunftsrate. Sie gibt die Anzahl der Calls pro Ankunftszeitintervall an und die *mittlere Ankunftsrate* λ kann berechnet werden aus:¹⁴⁴

$$\lambda = \frac{1}{n} \sum_{i=1}^k n_i z_i \quad (5.1)$$

n ... Anzahl aller Calls

z_i ... Anzahl der Calls pro Ankunftsintervall ($i = 0, 1, \dots, k$)

n_i ... absolute Häufigkeit für das Vorkommen der Anzahl an Calls z_i ($i = 0, 1, \dots, k$).

Für die Ankunftsraten werden verschiedene Annahmen unterstellt, so folgen sie zum einen einem *Markow-Prozess*¹⁴⁵, was übertragen auf die Anrufeingänge bedeutet ,

¹⁴⁴ Vgl. hierzu und im Folgenden Bokranz (1985), S. 9; Hillier/Lieberman (1997), S. 504f. und Gross/Harris (1985), S. 2f.

dass die Calls zufällig und unabhängig voneinander im Call Center eintreffen und zum anderen wird für die Anzahl der Anrufe, die in einem bestimmten Zeitintervall im Call Center eingehen, unterstellt, dass sie einer *Poissonverteilung* gehorcht. In diesem Zusammenhang wird von einem *Poissonprozess* gesprochen, dessen Bedeutung und weitere Eigenschaften werden in Kapitel 5.2.3 näher erläutert.

Alternativ zu den Ankunftsrate, kann auch die Zeitdauer zwischen zwei aufeinander folgenden Ankünften betrachtet werden. In diesem Fall wird dann auch von der sog. „*Interarrival time*“¹⁴⁶ oder *Zwischenankunftszeit* gesprochen. Die mittlere *Interarrival time* ist über

$$\bar{t}_{ar} = \frac{1}{\lambda} \tag{5.2}$$

zu berechnen.

Die Verteilung der Zeitdauer zwischen zwei Calls wird in der Literatur immer mit einer Exponentialverteilung angegeben.

¹⁴⁵ Die Definition eines Markow Prozesses lautet folgendermaßen (Hillier/Lieberman (1997), S. 479 und König/Stoyan (1976), S. 21f.):

Unter einem stochastischen Prozess $\{X_t\}$ wird eine Reihe von Zufallsvariablen X_t ($t = 0, 1, \dots, T$) verstanden, wobei X_t den Zustand des Systems zum Zeitpunkt t darstellt und Werte in einer vorgegebenen Menge M (Zustandsraum) von möglichen Zuständen annehmen kann. Als Markow-Prozess wird nun ein stochastischer Prozess bezeichnet, der folgende Eigenschaft bezüglich der Übergangswahrscheinlichkeiten erfüllt:

$$P\{X_{t+1} = j \mid X_0 = x_0, X_1 = x_1, \mathbf{K}, X_{t-1} = x_{t-1}, X_t = i\} = P\{X_{t+1} = j \mid X_t = i\} \quad \text{für } t = 0, 1, \dots \text{ und alle } i, j, x_0, x_1, \dots, x_{t-1}.$$

Diese Markow-Eigenschaft bedeutet also nichts anderes, als dass das Verhalten des Zustandes vor t keinen Einfluss auf den Zustand in $t + 1$ hat. Dieser ist lediglich abhängig vom Zustand in t .

¹⁴⁶ Vgl. hierzu und im Folgenden Hall (1991), S. 57.

5.2.2 Die Servicezeit

Die Servicezeit, also die Dauer der Bearbeitung eines Anrufs, ist die zweite zentrale Einflussgröße im Warteschlangensystem. Auch für sie wird häufig ein Markow-Prozess unterstellt, was bedeutet, dass auch hier die Servicezeiten von Agent zu Agent zufällig schwanken und voneinander unabhängig sind. Im Call Center wird die Bedienzeit ab dem Zeitpunkt der Durchstellung des Anrufers zu einem freien Operator bis zum Beenden des Gesprächs zwischen Kunde und Agent als Servicezeit oder Gesprächszeit bezeichnet.

Damit kann die mittlere Servicezeit als

$$\bar{t}_{st} = \frac{1}{n} \sum_{j=0}^k t_{abj} n_j \quad (5.3)$$

mit

n ... Stichprobenumfang

n_j ... Häufigkeit für das Auftreten der Servicezeit t_{abj}

t_{abj} ... Servicezeit eines Agenten mit der Dauer j ($0 < j \leq k$)

berechnet werden.¹⁴⁷ Auch hieraus ergibt sich die mittlere Servicerate μ durch den Kehrwert der mittleren Servicezeit:

$$\mu = \frac{1}{\bar{t}_{st}}. \quad (5.4)$$

Für die Verteilung der Bedienungsrate werden in der Literatur ebenfalls unterschiedliche Annahmen getroffen. Grundsätzlich kann sie beliebig verteilt sein, allerdings wird meistens (vor allem aber wenn es um die Servicezeiten in Call Centers geht) eine Exponentialverteilung angenommen, zumal sie gewisse Eigenschaften aufweist, die die Berechnung und Lösung von Warteschlangen-

¹⁴⁷ Vgl. hierzu und im Folgenden Bokranz (1985), S. 18f.

modellen vereinfachen.¹⁴⁸ Weiterführende Erläuterungen zur Bedeutung der Exponentialverteilung in der Warteschlangentheorie finden sich im folgenden Kapitel.

5.2.3 Die Bedeutung der Exponentialverteilung

Der Exponentialverteilung kommt eine tragende Rolle in der Warteschlangentheorie zuteil, da sie Eigenschaften aufweist, die für die Modellierung von Wartesystemen von erheblichem Vorteil sind. Dies ist auch der Grund, weshalb die Exponentialverteilung im Folgenden ausführlich dargestellt wird und ihr, für die Warteschlangentheorie wichtigen Eigenschaften dargelegt werden sollen.¹⁴⁹

Allgemein lautet die Dichtefunktion der Exponentialverteilung mit dem Verteilungsparameter α

$$f(X) = \alpha e^{-\alpha X} \quad X \geq 0 \quad (5.5)$$

und die zugehörige Verteilungsfunktion

$$F(X) = \int_0^X \alpha e^{-\alpha t} dt = 1 - e^{-\alpha X} . \quad (5.6)$$

Der Erwartungswert und die Varianz können gemäß

$$E(X) = \frac{1}{\alpha} \quad (5.7)$$

$$\text{Var}(X) = \frac{1}{\alpha^2} = E(X)^2 \quad (5.8)$$

¹⁴⁸ Vgl. Hall (1991), S. 111.

¹⁴⁹ Vgl. hierzu und im Folgenden Fahrmeir/Hamerle (1996), S. 42-48; Hall (1991), S. 57f und Allen (1978), S. 85.

berechnet werden.

Die wesentlichen Eigenschaften der Exponentialverteilung sind wie folgt:¹⁵⁰

Eigenschaft (I):

Die Markow-Eigenschaft des fehlenden *Erinnerungsvermögens* (*memoryless property*) gilt als der wesentliche Grund, weshalb die Exponentialverteilung gerade in den Warteschlangenmodellen von so großer Bedeutung ist. Es gilt nämlich allgemein

$$P\{X > t + h \mid X > t\} = P\{X > h\} \text{ mit } t > 0 \text{ und } h > 0. \quad (5.9)$$

Wird mit X nun die Wartezeit, bis ein neues Ereignis eintritt, definiert, so ist diese unabhängig von der bereits verstrichenen Wartezeit. Das System vergisst also, wie viel Zeit bereits vergangen ist, in dem kein Ereignis eintrat.

Wird als Ereignis die Ankunft eines neuen Calls definiert, so bedeutet dies übertragen auf den Kontext der Call Centers, dass das Eintreffen eines neuen Anrufs vollkommen unabhängig vom Eintreffen des Letzten ist. Damit wäre also auch die geforderte Zufälligkeit von Anrufeingängen (vgl. Kap. 5.2.1) gewährleistet, sofern für den Ankunftsprozess die Exponentialverteilung unterstellt wird.

Analog dazu kann auch die Servicezeit als Ereignis definiert werden, was dann wiederum bedeuten würde, dass auch hier die Bedienzeiten unabhängig von den zuvor abgefertigten Kunden sind.

Das System erinnert sich nicht an die Historie der Servicezeiten.

Der mathematische Beweis dieses fehlenden Erinnerungsvermögens der Exponentialverteilung wird wie folgt erbracht:

¹⁵⁰ Vgl. hierzu insbesondere Allen (1978), S. 82-85.

$$P\{X > t+h \mid X > t\} = \frac{P\{(X > t+h) \cap (X > t)\}}{P\{(X > t)\}} = \frac{P\{(X > t+h)\}}{P\{(X > t)\}} =$$

$$\frac{e^{-\alpha(t+h)}}{e^{-\alpha t}} = \frac{e^{-\alpha t} \cdot e^{-\alpha h}}{e^{-\alpha t}} = e^{-\alpha h} = P\{X > h\}. \quad (5.10)$$

Eigenschaft (II):

Ein weiteres Charakteristikum der Exponentialverteilung ist, dass sie nicht symmetrisch zum Erwartungswert ist.

Der Beweis hierfür ist einfach zu erbringen, denn unter der Annahme einer exponentialverteilten Zufallsvariablen X mit dem Parameter α , ist die Wahrscheinlichkeit, dass sie einen Wert kleiner als den Erwartungswert annimmt:

$$P\{X \leq E(X)\} = 1 - e^{-\alpha \cdot E(X)} = 1 - e^{-\alpha \cdot \left(\frac{1}{\alpha}\right)} = 1 - e^{-1} = 0,63212.$$

Dies bedeutet, dass die Wahrscheinlichkeit, einen Wert kleiner gleich dem Erwartungswert anzunehmen, in etwa 63,212% beträgt. Übertragen auf die Notation von Call Center hätte dies folgende Bedeutung:

Stellt X etwa die Bedienzeit mit der mittleren Servicerate μ dar, so würden die meisten Calls innerhalb der mittleren Servicezeit (gemäß (5.4)) abgefertigt werden. Dies ist intuitiv plausibel, zumal die meisten Anrufe ohnehin Routinetätigkeiten erfordern, die relativ rasch zu erledigen sind. Nur vereinzelt können auch Anfragen eintreffen, die einer umfangreicheren Bearbeitung bedürfen und damit auch die durchschnittliche Servicezeit überschreiten können.

Eigenschaft (III):

Eine weitere Eigenschaft der Exponentialverteilung ist, dass das Minimum einer Zufallsvariablen T , die sich aus einer Reihe von unabhängigen, exponentialverteilten Zufallsvariablen X_1, X_2, \dots, X_n mit den Verteilungsparametern

$\alpha_1, \alpha_2, \dots, \alpha_n$ zusammensetzt, wiederum einer Exponentialverteilung mit dem Parameter $\alpha = \sum_{i=1}^n \alpha_i$ entspricht.

Gilt beispielsweise $T = \min\{X_1, X_2, \dots, X_n\}$, dann gilt für jedes T mit der Eigenschaft $T > t$ zudem $X_1 > t, X_2 > t, \dots, X_n > t$.

Dies hat folgende Auswirkung auf die Wahrscheinlichkeit, dass T einen Wert größer t annimmt:

$$P\{T > t\} = P\{X_1 > t, X_2 > t, \dots, X_n > t\}, \quad (5.11)$$

was bei der zuvor unterstellten Unabhängigkeit der Variablen äquivalent ist zu

$$\begin{aligned} P\{T > t\} &= P\{X_1 > t\} \cdot P\{X_2 > t\} \cdot \dots \cdot P\{X_n > t\} = e^{-\alpha_1 t} \cdot e^{-\alpha_2 t} \cdot \dots \cdot e^{-\alpha_n t} = \\ &= \exp\left\{-\sum_{i=1}^n \alpha_i t\right\}. \end{aligned} \quad (5.12)$$

Auch diese Tatsache kann wieder in den Kontext der Call Center Thematik übertragen werden. Wird unterstellt, dass X_i die Interarrivalzeiten angeben und weiterhin angenommen wird, dass das Call Center unterschiedliche Anrufarten bearbeitet, so stellt X_i allgemein die Zeit zwischen zwei Calls des Typs i dar, wobei diese zudem einer Exponentialverteilung mit dem expliziten Parameter α_i folgt.

Da alle Calltypen in ein und demselben Call Center eingehen, muss auf eine Gesamtbetrachtung der Interarrivalzeiten aller Anrufe übergegangen werden, was in diesem Fall bedeuten würde, dass unabhängig des Anruftyps die Zeitdauer zwischen zwei Anrufen exponentialverteilt ist mit $\sum_{i=1}^n \alpha_i$.

T wäre in diesem Fall also die insgesamt minimalste Zeit zwischen zwei Anrufen. Analoges kann auf die Servicezeiten übertragen werden. Unterstellt wird dann wiederum, dass insgesamt n Operatoren im Call Center zur Verfügung stehen und

alle eine identische Servicezeit aufweisen, die jeweils mit dem Parameter μ exponentialverteilt ist. Wird X_i nun als jene Zeitspanne aufgefasst, bis der Agent i mit der Bearbeitung seines Kunden fertig ist, so würde, übertragen auf das Gesamtsystem, die Restzeit bis einer der n Operatoren wieder frei wird, wieder T mit dem Verteilungsparameter $n \cdot \mu$ entsprechen.

Eigenschaft (IV):

Die wohl zentralste und damit wichtigste Eigenschaft ist die Verbindung der Exponentialverteilung zur Poissonverteilung.¹⁵¹ Wird mit T wieder allgemein die Zeit zwischen zwei Ankünften postuliert und interessiert die Wahrscheinlichkeit, dass in einem Zeitintervall t genau k Anrufe eintreffen, wenn T mit λ exponentialverteilt ist.

Wird das betrachtete Zeitintervall t nun in m gleichmäßige kleine Zeitabschnitte Δt unterteilt (wobei gilt $t = m \cdot \Delta t$), so können die beiden Wahrscheinlichkeiten berechnet werden, dass zum einen im Zeitabschnitt Δt ein Anruf eintrifft und die entsprechende Gegenwahrscheinlichkeit, dass in diesem Zeitintervall eben kein Anruf im Call Center erfolgt. Das Eintreffen eines Calls ist äquivalent zur Aussage, dass die Zeitdauer T zwischen zwei Anrufen kleiner ist, als der betrachtete Zeitabschnitt Δt bzw. für das Nichteintreffen, dass die Zeit zwischen zwei Anrufen größer ist als Δt .

¹⁵¹ Vgl. hierzu und im Folgenden speziell Hall (1991), S. 58; Gross/Harris (1985), S. 24 und König/Stoyan (1976), S. 31-34.

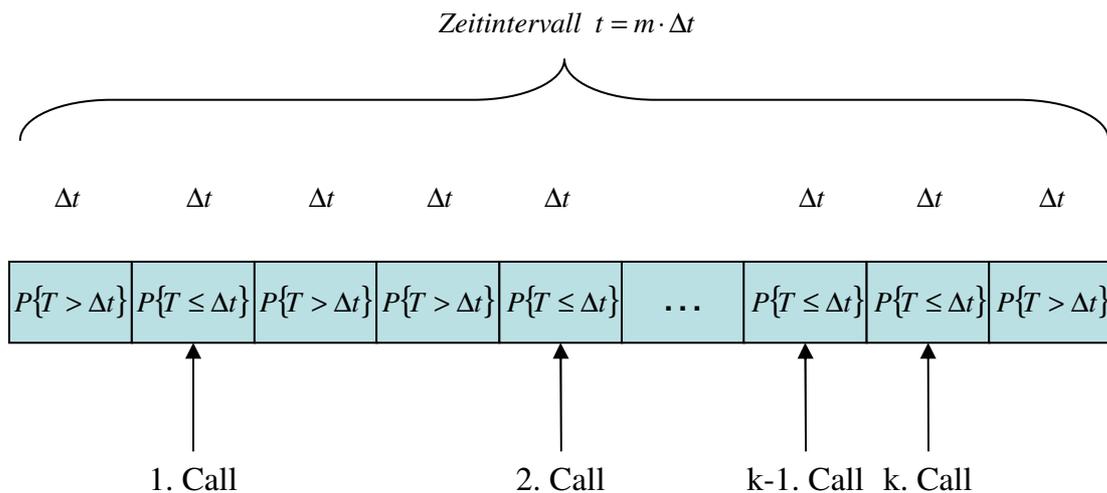


Abbildung 5.4: Aufteilung eines Zeitintervalls t in m Einzelintervalle

Obige Grafik stellt nochmals den Zusammenhang zwischen der Aufspaltung des Zeitintervalls t in m Einzelintervalle und der Unterscheidung, ob ein Anruf im Call Center eintrifft oder nicht, dar.

Für die entsprechenden Wahrscheinlichkeiten können folgende Berechnungsarten angegeben werden:

$P\{T \leq \Delta t\}$... Wahrscheinlichkeit für das Eintreffen eines Anrufs im Zeitabschnitt Δt

$$= 1 - e^{-\lambda \Delta t} \tag{5.13}$$

und

$P\{T > \Delta t\}$... Wahrscheinlichkeit für das Nichteintreffen eines Anrufs im Zeitabschnitt Δt

$$= e^{-\lambda \Delta t} . \tag{5.14}$$

Diese Wahrscheinlichkeiten wiederum sind äquivalent zu¹⁵²

¹⁵² Vgl. König/Stoyan (1976), S. 17.

$$P\{T \leq \Delta t\} = 1 - e^{-\lambda \Delta t} \approx \lambda \Delta t \quad (5.15)$$

und

$$P\{T > \Delta t\} = e^{-\lambda \Delta t} \approx 1 - \lambda \Delta t. \quad (5.16)$$

Damit kann nun die Wahrscheinlichkeit berechnet werden, dass in den m Zeitintervallen genau k Calls eingehen. Da es sich hierbei um ein dichotomes Merkmal handelt (Anruf geht im Call Center ein oder nicht), wobei die Anrufeingänge des weiteren stochastisch unabhängig sind, kann für die Wahrscheinlichkeitsberechnung die Binomialverteilung angesetzt werden:

$$\begin{aligned} P\{K = k\} &= \binom{m}{k} (P\{T \leq \Delta t\})^k \cdot (P\{T > \Delta t\})^{m-k} = \\ &= \frac{m!}{(m-k)!k!} \cdot (\lambda \Delta t)^k \cdot (1 - \lambda \Delta t)^{m-k}. \end{aligned} \quad (5.17)$$

Da $\Delta t = \frac{t}{m}$ gilt

$$\begin{aligned} P\{K = k\} &= \frac{m!}{(m-k)!k!} \cdot \left(\lambda \frac{t}{m}\right)^k \cdot \left(1 - \lambda \frac{t}{m}\right)^{m-k} = \\ &= \frac{m! (\lambda t)^k}{(m-k)!k! m^k} \cdot \left(1 - \lambda \frac{t}{m}\right)^{m-k}. \end{aligned} \quad (5.18)$$

Wird zudem unterstellt, dass $m \gg k$ ist, so folgt:

$$P\{K = k\} = \frac{(\lambda t)^k}{k!} \cdot 1 \cdot \left(1 - \lambda \frac{t}{m}\right)^m. \quad (5.19)$$

Die Grenzwertbetrachtung für $m \rightarrow 0$ liefert dann:¹⁵³

$$P\{K = k\} = \frac{(\lambda t)^k}{k!} \cdot e^{-\lambda t}, \quad (5.20)$$

so dass hierbei die Poissonverteilung resultiert.

Sie gibt an, wie groß die Wahrscheinlichkeit ist, dass in einem Zeitintervall t genau k Anrufe eintreffen, wenn die Interarrivalzeiten dieser Anrufe exponentialverteilt sind mit dem Parameter λ .

Der Erwartungswert der Anzahl der Anrufe ist dabei λt , was also der mittleren Ankunftsrate pro Zeiteinheit von λ entspricht.

Der Zählprozess, nämlich dass genau k Anrufe in einem Zeitintervall vorkommen, wird auch als *Poissonprozess* bezeichnet.¹⁵⁴

In Verbindung mit den Ankünften bedeutet dies, dass aus den exponentialverteilten Zwischenankunftszeiten mit einem Erwartungswert von $\frac{1}{\lambda}$, die Anzahl der Ankünfte mit einer mittleren Ankunftsrate von λ berechnet werden können.

Gerade diese Übergangsmöglichkeit von stetig verteilten Interarrivalzeiten auf die diskrete Verteilung der Anzahl von Calls im gleichen Betrachtungszeitraum, wird in späteren Kapiteln der Warteschlangentheorie noch eine wichtige Rolle spielen.

Eigenschaft (V):

Eine weitere Eigenschaft der Exponentialverteilung, die zu einem späteren Zeitpunkt der Arbeit von großer Bedeutung sein wird, besteht in der Verwandtschaft zur Gammaverteilung. Im Falle von n unabhängigen exponentialverteilter Zufallsvariablen mit dem Parameter λ , die zudem unabhängig voneinander sind, resultiert aus deren Summe eine Gammaverteilung mit den Parametern n und λ , wobei deren Dichtefunktion dann lautet:

¹⁵³ Vgl. Hall (1991), S. 55.

¹⁵⁴ Vgl. Allen (1978), S. 117 und Hall (1991), S. 56f.

$$f(x) = \begin{cases} \frac{\lambda(\lambda x)^{n-1} e^{-\lambda x}}{\Gamma(n)} & x > 0 \\ 0 & x \leq 0 \end{cases} . \quad (5.21)$$

Diese Eigenschaft wird vor allem in Kapitel 5.4.2 bei der Bestimmung der Verteilung der Verweildauer eines beliebigen Anrufers in der Warteschlange nochmals Anwendung finden.

5.2.4 Der Geburts- und Sterbeprozess

Eine wesentliche Annahme vieler Warteschlangenmodelle ist, dass sich die eingehenden und die wieder abgehenden, also beendeten Anrufe, gemäß eines so genannten „*Birth and Death Process*“¹⁵⁵ (Geburts- und Sterbeprozess) entwickeln.

Als *Geburt* wird dabei das Eintreffen eines neuen Kunden im Call Center bezeichnet und das *Sterben* bedeutet das Ausscheiden des Kunden aus dem System.

Mit Hilfe des Geburts- und Sterbeprozesses sollen allgemein die Zustandsänderungen des Gesamtsystems erklärt und berechnet werden können, wenn ein- und ausgehende Anrufe zu beachten sind.

Um dies allerdings bewerkstelligen zu können, bedarf es eines expliziten Annahmensystems:¹⁵⁶

ANNAHME (I)

Es wird ein kontinuierlicher stochastischer Prozess mit einem diskreten Zustandsraum unterstellt, wobei mit $X(t)$ der Systemzustand zum Zeitpunkt t ($t \geq 0$) dargestellt wird, d. h. er sagt aus, wie viele Anrufer zum Zeitpunkt t im Call Center sind.

¹⁵⁵ Vgl. Bhat (1984), S. 216-219.

¹⁵⁶ Vgl. hierzu und im Folgenden Allen (1978), S. 121-129. und König/Stoyan (1976), S. 29-31.

ANNAHME (II)

Ausgehend von einem bestimmten Systemzustand $X(t) = n$, es wird in diesem Zusammenhang auch von einer Population von n Elementen gesprochen, ist die Zeit bis zum nächsten Eintreffen eines Anrufers exponentialverteilt mit λ_n ($n = 0, 1, 2, \dots$), wobei diese Ankunftsrate konstant sind.

ANNAHME (III)

Analog zur Geburtsverteilung wird auch unterstellt, dass ausgehend vom Zustand $X(t) = n$ die Zeit bis zum Ausscheiden eines Anrufers aus dem Call Center (Sterbefall) ebenfalls exponentialverteilt ist mit μ_n ($n = 1, 2, \dots$). Auch diese Serviceraten werden im Geburts- und Sterbeprozess als konstant angenommen.

ANNAHME (IV)

Bei einer Population von n Elementen ($X(t) = n$) treten die Geburten und Sterbefälle unabhängig voneinander auf und die jeweiligen Ankunfts- und Serviceraten sind stochastisch unabhängig voneinander.

ANNAHME (V)

Die Wahrscheinlichkeit dafür, dass zu einem Zeitpunkt t mehr als eine Geburt oder ein Sterbefall auftritt, ist verschwindend gering, so dass faktisch davon ausgegangen wird, dass in einem bestimmten Zeitpunkt nur eine Geburt oder ein Sterbefall auftritt.

Um die Systemzustände auch grafisch abbilden zu können, wird oft ein so genannter *Übergangsgraph (transition rate diagram)*¹⁵⁷ zu Hilfe genommen, der die unten dargestellte Form aufweist. Entscheidend dabei ist, dass in den kleinen Zeitintervallen, die gemäß Annahme (V) konsequenterweise resultieren müssen, Übergänge vom Zustand n aus immer nur in die Nachbarzustände $(n+1)$ (Geburt) und $(n-1)$ (Tod) stattfinden.

¹⁵⁷ Vgl. Hall (1991), S. 138.

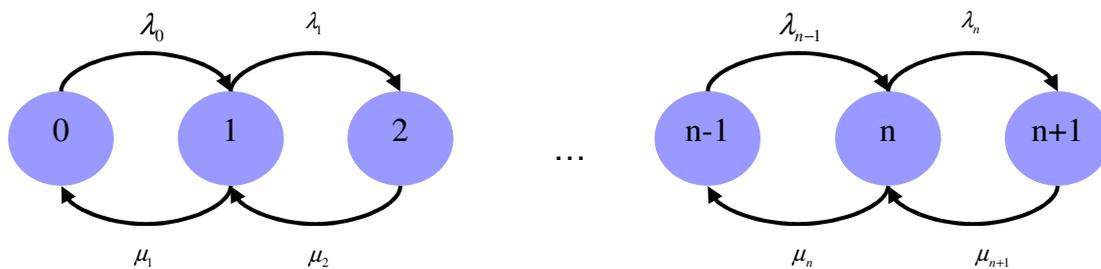


Abbildung 5.5: Übergangsgraph zur Darstellung des Geburts- und Sterbeprozesses

Der Pfeilursprung repräsentiert dabei stets die Ausgangsposition und die Pfeilrichtung deutet die Übergangsraten in den nächsten Zustand an. Wird beispielsweise von der Ausgangssituation mit einem Anrufer ausgegangen ($n=1$), so würde das System mit einer Übergangswahrscheinlichkeit von λ_1 in den Zustand $n=2$ und mit einer Übergangswahrscheinlichkeit von μ_1 in den Zustand $n=0$ wechseln.

Von einem reinen Geburtsprozess wird dann gesprochen, wenn alle mittleren Serviceraten μ_n Null sind und analog dazu liegt ein reiner Sterbeprozess vor, wenn alle mittleren Ankunftsrate λ_n dementsprechend Null sind.

Was für den praktischen Nutzen im Call Center Betrieb hauptsächlich von Interesse ist, ist die Möglichkeit, ausgehend von einem bestimmten Systemzustand und der Kenntnis von den entsprechenden Ankunfts- und Serviceraten, wichtige Größen wie die mittlere Wartezeit der Kunden in der Warteschlange oder die benötigte Anzahl an Agenten zu berechnen, um die Servicequalität auf einem möglichst hohen Niveau halten zu können. Die Analyse der Geburts- und Sterbeprozesse ermöglicht weiterhin die Entwicklung von Modellen, die unter Berücksichtigung der Call Center-spezifischen Einflussparameter Rückschlüsse auf die optimale Anzahl an Agenten im System erlauben. Ein Modell hat sich dabei besonders in der Personaleinsatzplanung von Call Center etabliert und wird auch in Kapitel 5.4 ausführlich dargestellt. Zunächst sollen aber die Grundlagen für das weiterführende Modell geschaffen werden.

Als erstes Ziel soll hierzu die Wahrscheinlichkeit abgeleitet werden, dass sich das System zum Zeitpunkt t im Zustand n befindet, also

$$P_n(t) = P\{X(t) = n\}. \quad (5.22)$$

Bei dieser Definition der Zustandswahrscheinlichkeit des Systems zum Zeitpunkt t eröffnet sich allerdings die Problematik, dass die Zeitkomponente zu beachten ist und damit das System *transitorische* Zustände hat. Deren Analyse wird allerdings erst durch Monte-Carlo Simulationen möglich und weniger durch algebraische Ansätze. Aus Vereinfachungsgründen wird deshalb immer auf *stationäre Zustände* (*steady state*)¹⁵⁸ übergegangen, d. h. es werden Modelle betrachtet, deren Zustände und deren Verteilungen zeitunabhängig sind. Dies gilt sowohl für den Ankunftsprozess als auch für den Serviceprozess.¹⁵⁹

Dabei stellt sich allerdings die Frage, wann ein System einen derartigen steady-state Zustand annimmt, wann sich das System also in einem Gleichgewichtszustand befindet. Zur Illustration wird hierfür nochmals auf den Übergangsgraphen von Abbildung 5.5 verwiesen. Das Gleichgewicht in einem beliebigen Zustand n lässt sich dann gemäß dem Prinzip gleicher Raten für eingehende Anrufe und beendete Anrufe ableiten („*Flow Rate In = Flow Rate Out Principle*“).¹⁶⁰ Die Raten, die das Eintreten in den Zustand n bewirken, müssen genauso groß sein wie die Raten, die das Verlassen des Zustands n verursachen. Wird dieses Prinzip nun auf alle möglichen Systemzustände ($n = 0, 1, 2, \dots$) übertragen, so resultieren hieraus die *Gleichgewichtsgleichungen* („*balance equations*“¹⁶¹) für alle n Zustände in Abhängigkeit der unbekannteren Zustandswahrscheinlichkeiten P_n . Durch sukzessives Einsetzen und Auflösen der Gleichungen sind daraus letztendlich die gesuchten Zustandswahrscheinlichkeiten ermittelbar.

¹⁵⁸ Hall (1991), S. 131.

¹⁵⁹ In diesem Fall wird dann auch von stationären Prozessen gesprochen.

¹⁶⁰ Vgl. Allen (1978), S. 128.

¹⁶¹ Vgl. Hall (1991), S. 136.

In Anlehnung an den Übergangsgraph resultieren für die unterschiedlichen Systemzustände folgende Gleichgewichtsgleichungen:

| <u>Zustand</u> | <u>Gleichgewichtsbedingung</u> |
|----------------|---|
| 0 | $\mu_1 \cdot P_1 = \lambda_0 \cdot P_0$ |
| 1 | $\lambda_0 \cdot P_0 + \mu_2 \cdot P_2 = \lambda_1 \cdot P_1 + \mu_1 \cdot P_1$ |
| 2 | $\lambda_1 \cdot P_1 + \mu_3 \cdot P_3 = \lambda_2 \cdot P_2 + \mu_2 \cdot P_2$ |
| ... | ... |
| n | $\lambda_{n-1} \cdot P_{n-1} + \mu_{n+1} \cdot P_{n+1} = \lambda_n \cdot P_n + \mu_n \cdot P_n$ |

Unter der Bedingung, dass die Summe über alle Zustandswahrscheinlichkeiten Eins sein muss, also

$$\sum_{n=0}^{\infty} P_n = 1, \quad (5.23)$$

können nun die Zustandswahrscheinlichkeiten P_n wie folgt berechnet werden.

| <u>Zustand</u> | <u>Gleichgewichtsbedingung</u> |
|----------------|---|
| 0 | $P_1 = \frac{\lambda_0}{\mu_1} \cdot P_0$ |
| 1 | $P_2 = \frac{\lambda_1}{\mu_2} \cdot P_1 + (\mu_1 \cdot P_1 - \lambda_0 \cdot P_0) \cdot \frac{1}{\mu_2} = \frac{\lambda_1}{\mu_2} \cdot P_1 = \frac{\lambda_1 \lambda_0}{\mu_2 \mu_1} P_0$ ¹⁶² |
| 2 | $P_3 = \frac{\lambda_2}{\mu_3} \cdot P_2 + (\mu_2 \cdot P_2 - \lambda_1 \cdot P_1) \cdot \frac{1}{\mu_3} = \frac{\lambda_2}{\mu_3} \cdot P_2 = \frac{\lambda_2 \lambda_1 \lambda_0}{\mu_3 \mu_2 \mu_1} P_0$ |
| ... | ... |
| n | $P_{n+1} = \frac{\lambda_n}{\mu_{n+1}} \cdot P_n + (\mu_n \cdot P_n - \lambda_{n-1} \cdot P_{n-1}) \cdot \frac{1}{\mu_{n+1}} = \frac{\lambda_n}{\mu_{n+1}} \cdot P_n = \frac{\lambda_n \lambda_{n-1} \Lambda \lambda_0}{\mu_{n+1} \mu_n \Lambda \mu_1} P_0$ |

Wird noch die zusätzliche Definition von

$$C_n = \frac{\lambda_{n-1} \lambda_{n-2} \Lambda \lambda_0}{\mu_n \mu_{n-1} \Lambda \mu_1} \text{ für } n = 1, 2, \dots \quad (5.24)$$

miteinanderbeziehen, so folgt für die Zustandswahrscheinlichkeit im stationären Zustand allgemein

$$P_n = C_n P_0. \quad (5.25)$$

Dies bedeutet also, dass jede Zustandswahrscheinlichkeit auf Grundlage der Wahrscheinlichkeit berechnet werden kann, dass das System leer ist. Folglich ist die Berechnung der Wahrscheinlichkeit für den Ausgangszustand von Interesse.

In Verbindung mit Gleichung (5.23) resultiert aus (5.25) dann

¹⁶² Der Übergang von $P_2 = \frac{\lambda_1}{\mu_2} \cdot P_1 + (\mu_1 \cdot P_1 - \lambda_0 \cdot P_0) \cdot \frac{1}{\mu_2}$ auf $\frac{\lambda_1}{\mu_2} \cdot P_1 = \frac{\lambda_1 \lambda_0}{\mu_2 \mu_1} P_0$ folgt durch Beachtung der Gleichung von Zustand 0, die besagt, dass gemäß $\mu_1 \cdot P_1 = \lambda_0 \cdot P_0$ gilt: $\mu_1 \cdot P_1 - \lambda_0 \cdot P_0 = 0$. Somit reduziert sich die Gleichung auf $\frac{\lambda_1}{\mu_2} \cdot P_1$ und damit $\frac{\lambda_1 \lambda_0}{\mu_2 \mu_1} P_0$.

Analoges gilt auch für die weiteren Gleichungen.

$$\sum_{n=0}^{\infty} C_n P_0 = 1$$

$$P_0(C_0 + C_1 + K + C_{\infty}) = 1$$

$$P_0 \left(1 + \frac{\lambda_0}{\mu_1} + \frac{\lambda_0 \lambda_1}{\mu_1 \mu_2} + K + \dots \right) = 1$$

$$P_0 \left(1 + \sum_{n=1}^{\infty} C_n \right) = 1$$

$$P_0 = \frac{1}{1 + \sum_{n=1}^{\infty} C_n} \quad (5.26)$$

Dieses Ergebnis ist nun aus zweierlei Hinsicht von Bedeutung:

Unter der Annahme, dass die Ankunfts- und Serviceraten λ_n und μ_n jeweils positiv sind, ist diese Wahrscheinlichkeit dafür, dass das System leer ist, ebenfalls positiv, was übertragen auf das Warteschlangenmodell wiederum impliziert, dass das Call Center in der Lage ist, alle Kunden abzufertigen und damit in einen Art Ruhezustand zu kommen. Sind allerdings die Ankunftsrate größer als die Serviceraten, so divergiert das System ($\sum_{n=1}^{\infty} C_n \rightarrow \infty$) und die Wahrscheinlichkeit für P_0 sinkt, was

faktisch bedeutet, dass das Wartesystem instabil ist.

Da sich alle Zustandswahrscheinlichkeiten berechnen lassen, sofern die Ankunfts- und Serviceraten bekannt sind, können darauf aufbauend weitere wichtige Größen berechnet werden. Die Einfachste dabei ist die *erwartete Anzahl an Anrufern* L_S , die sich im *Gesamtsystem* befinden:¹⁶³

$$L_S = \sum_{n=0}^{\infty} n P_n \quad (5.27)$$

¹⁶³ Vgl. hierzu und im Folgenden Hall (1991), S. 133.

In einem Call Center ist aber oftmals nicht die erwartete Anzahl an Kunden im Gesamtsystem von Interesse, sondern die *erwartete Anzahl an Anrufern in der Warteschlange* (L_q). Diese Größe kommt vor allem dann zum Tragen, wenn es um die Frage des Servicelevels und damit um die zumutbare Wartezeit in der Schlange geht.

Diese erwartete Warteschlangenlänge kann aus der erwarteten Anzahl an Kunden im Gesamtsystem abgeleitet werden, indem die jeweilige Gesamtanzahl an Kunden n jeweils um die Anzahl der Kunden korrigiert wird, die gerade von den insgesamt c Agenten bearbeitet werden.

$$L_q = \sum_{n=c}^{\infty} (n - c) P_n \quad (5.28)$$

Neben der Anzahl der Kunden im System oder in der Warteschlange ist auch die *absolute Wartezeit im Gesamtsystem* (W_s) oder in der *Warteschleife* (W_q) von Bedeutung. Die Wartezeit im Gesamtsystem setzt sich dabei aus der Wartezeit in der Schlange W_q und der eigenen Bedienzeit $\frac{1}{\mu}$ zusammen.

Entscheidend ist, dass sich diese beiden Größen W_s und W_q anhand der bereits dargestellten Parameter L_s und L_q ableiten lassen. *John D. C. Little* hat zwischen diesen Werten folgende Zusammenhänge abgeleitet, die auch als die „*Formeln von Little*“ (*Little's formula, Little's law*) in der Literatur Eingang gefunden haben (auf einen Nachweis wird hierbei verzichtet und auf die entsprechende Literaturquelle verwiesen):¹⁶⁴

$$L_s = \lambda W_s, \quad (5.29)$$

wobei λ für alle λ_n eine Konstante darstellt, d. h. für alle λ_n wird eine durchschnittliche Ankunftsrate unterstellt.

¹⁶⁴ Little (1961), S. 383-387.

Analog dazu gilt dann auch für die Anzahl der Anrufer in der Warteschlange L_q der entsprechende Zusammenhang mit der Wartezeit in der Warteschlange W_q mit

$$L_q = \lambda W_q . \quad (5.30)$$

Die einzige Annahme, die hier unterstellt wird, ist, dass das Zeitintervall zu Beginn und am Ende der Betrachtung keine Kunden im System aufweist.

Mit Hilfe dieser beiden Formeln lassen sich nun bei gegebenen Werten von L_s und L_q die jeweiligen Wartezeiten W_s und W_q berechnen:

$$W_s = \frac{L_s}{\lambda} \quad (5.31)$$

und

$$W_q = \frac{L_q}{\lambda} . \quad (5.32)$$

Diese eben abgeleiteten Warteschlangengrößen werden auch in den nachfolgenden Modellen eine wesentliche Rolle spielen.

5.3 Die Kendall-Symbolik

Zur Kennzeichnung von Bedienungssystemen hat sich in der Literatur die Symbolik nach Kendall durchgesetzt. Die wesentlichen Komponenten können allgemein wie folgt dargestellt werden:

$$A/B/c/n$$

Durch den Buchstaben A wird die Verteilung der Ankunfts- bzw. Interarrivalzeiten angegeben, der Buchstabe B bezieht sich auf die Verteilung der Servicezeiten.

Für die entsprechenden Verteilungen werden wiederum folgende allgemeinen Abkürzungen verwendet:¹⁶⁶

| | | |
|----------------------|---------------------|---|
| GI / G | general independent | Ankunfts- bzw. Servicezeiten sind unabhängig und besitzen eine beliebige, wenn auch identische Verteilungsfunktion. |
| M | Markow | Poisson-Prozess bzw. Exponentialverteilung |
| E_k | Erlang | Erlangverteilung mit dem Verteilungsparameter k |
| D | deterministisch | konstante Abstände |

Tabelle 5.1: Bedeutung der Abkürzungen in der Kendall-Symbolik

Die Größe c definiert in diesem Zusammenhang die Anzahl der Bedienerstellen, das heißt im Kontext von Call Center, die Anzahl der Operator im System und n spiegelt letztendlich die Anzahl der vorhandenen Warteplätze im Warteschlangensystem wieder.

¹⁶⁵ Vgl. Gnedenko/König (1983), S. 38.

¹⁶⁶ Vgl. hierzu und im Folgenden: Gnedenko/König (1983), S. 27; Hillier/Lieberman, (1997), S. 507f.

Sofern keinerlei Warteplätze vorhanden sind, würde dies einem so genannten Verlustsystem entsprechen, da alle eingehenden Anrufe nicht in eine Warteschlange gestellt werden können, sobald alle Bedienerstellen besetzt sind. Diese zusätzlichen Calls werden stattdessen geblockt.

Das andere Extrem hierzu wäre eine unbegrenzte Warteschlange ($n=\infty$). Hierbei wird von einem reinen Wartesystem mit unendlich vielen Warteplätzen gesprochen. Für alle übrigen Modellierungen zwischen diesen beiden Extremen wird schließlich ein kombiniertes Warte-Verlust-System gekennzeichnet.

Des Weiteren hat sich in der Kendall-Symbolik eine Vektorbezeichnung (entsprechend bei $\overset{\vee}{A}$ und $\overset{\vee}{B}$) eingebürgert, wodurch zum Ausdruck gebracht werden soll, dass die voneinander unabhängigen Ankunfts- und Bedienungszeiten nicht notwendigerweise identisch verteilt sind, sondern dass die Verteilungsfunktionen unterschiedliche Parameter besitzen, die wiederum vom Operator selbst oder von der Callintensität im Call Center abhängen. In diesem Zusammenhang wird auch von dynamischen Verteilungen gesprochen.

In Verbindung mit Warteschlangensystemen sind auch die Prioritätsregeln festzulegen. Nach diesen wird bestimmt, in welcher Reihenfolge die wartenden Kunden zur Bedienung ausgewählt werden. Hierbei lassen sich folgende Regeln unterscheiden:¹⁶⁷

FIFO = FCFS (first in - first out; first come - first served):

Die Anrufer werden in der Reihenfolge ihres Eintreffens bearbeitet.

LIFO = LCFS (last in – first out; last come – first served):

Die Anrufer werden in umgekehrter Reihenfolge ihres Eintreffens abgefertigt.

SIRO (service in random order):

Die Bearbeitung eines wartenden Anrufers erfolgt zufällig.

¹⁶⁷ Vgl. hierzu und im Folgenden Gnedenko/König (1983), S.21; König/Stoyan (1976), S. 37; Gross/Harris (1985), S. 555.

Neben diesen einfachen Warteschlangendisziplinen sind in manchen Fällen noch zusätzliche Prioritäten zu beachten. Dies ist immer dann der Fall, wenn die Anrufe bestimmte Dringlichkeiten besitzen. Entsprechend dieser Dringlichkeiten werden den Calls Prioritäten zugeordnet.¹⁶⁸

- **Absolute Priorität (preemptive discipline)**

In diesem Fall wird die Bearbeitung eines Anrufs unterbrochen, sobald ein Call höherer Priorität eintrifft. Was die Wiederaufnahme des unterbrochenen Calls angeht, so kann unterschieden werden zwischen einer „preemptive loss discipline“ (der Anruf niedrigerer Ordnung wird komplett abgebrochen), „preemptive resume discipline“ (der Anruf wird nach der Bearbeitung des Calls höherer Ordnung wieder fortgesetzt) und „preemptive repeat different discipline“ (der Call niedrigerer Ordnung wird neu begonnen und damit neu bearbeitet).¹⁶⁹

- **Relative Priorität (HOL = head of the line priority discipline; non preemptive discipline)**

Hierbei erfolgt keine sofortige Unterbrechung der Bearbeitung des Calls niedrigerer Priorität, sobald ein Call höherer Priorität eintrifft. Es wird gewartet bis der Call abgearbeitet ist und dann erst wieder der neue Anruf entgegengenommen. Der Kunde mit der höheren Priorität nimmt demnach lediglich den ersten Platz in der Warteschlange ein.

Neben diesen eher „statischen“¹⁷⁰ Prioritätsregeln werden neuerdings auch dynamische angewendet. Dies gestaltet sich derart, dass in Abhängigkeit des Systemzustands die wartenden Calls eine höhere Priorität zugeteilt bekommen. Dieser Fall tritt immer dann ein, wenn die Wartezeit eines Anrufers einen bestimmten Grenzwert überschreitet. Dem Anrufer wird eine höhere Priorität zugeordnet, so dass er automatisch in der Warteschlange weiter nach vorne rückt.

¹⁶⁸ Vgl. Allen (1978), S. 213; König/Stoyan (1976), S.37.

¹⁶⁹ Ebenda S. 213 und S. 37.

¹⁷⁰ Helber/Stolletz (2004a), S. 109.

In den herkömmlichen Call Centern wird allerdings meistens die FIFO-Regel ohne zusätzliche Prioritäten angewendet. Dieses Prinzip wird auch später im empirischen Teil der Arbeit Eingang finden.

5.4 Das Erlang Modell als Grundlage der traditionellen Ermittlung des Personalbedarfs

Das zentrale Modell der Personaleinsatzplanung in Call Centern ist in der Praxis das so genannte Erlang C-Modell, das nach der Kendall-Notation auch als *M/M/c-Modell* bekannt ist.

Obwohl dieses Modell sehr restriktiven Annahmen unterliegt, dient es immer noch als Grundlage für die Ermittlung des optimalen Agentenstammes, der zu einer bestimmten Zeit im Call Center im Einsatz sein muss, damit die Anruflast bei einem vorgegebenen Servicelevel aufrecht erhalten werden kann.

Im Folgenden soll dieses Modell ausführlich dargestellt und damit die theoretischen Grundlagen für die Simulationsstudie in Kapitel 6 gelegt werden.

5.4.1 Das Annahmensystem

Essentiell für jedes statistische Modell ist zunächst die Festlegung der Rahmenbedingungen und damit der Anwendungsvoraussetzungen.¹⁷¹

Für das Erlang C-Modell sind dies die folgenden:

Annahme I:

Die Interarrivalzeiten sind exponentialverteilt, es liegt also ein Poissonprozess vor, wobei die mittlere Ankunftsrate mit jeweils λ_n festgelegt wird.

¹⁷¹ Vgl. hierzu und im Folgenden Helber/Stolletz (2004b), S. 72; Gross/Harris (1985), S. 101f.; Allen (1978), S. 176f. und Cleveland/Mayben/Greff (1998), S. 89f.

Annahme II:

Die Servicezeiten sind ebenfalls exponentialverteilt mit der mittleren Servicerate μ_n .

Annahme III:

Die Interarrivalzeiten und die Servicezeiten sind jeweils konstant und sowohl untereinander als auch vom Systemzustand unabhängig.

Annahme IV:

Insgesamt stehen c Operatoren im Call Center zur Verfügung, wobei diese (ebenso wie die Kunden) homogen sind, d.h. sie sind keine Agenten für spezielle Anrufer, sondern können grundsätzlich alle Anrufe bearbeiten. Sie weisen alle die gleichen Skills auf, die für den Einsatz im Call Center von Nöten sind.

Annahme V:

Die Warteschlange ist unendlich, d.h. kein Anrufer erhält ein Besetztzeichen, wenn alle Operatoren beschäftigt sind, was folglich bedeutet, dass die Anrufer geblockt werden. Dieser Fall tritt in diesem Modell aber nicht ein, sondern hier werden die Anrufer unabhängig von der Länge der Warteschlange in diese eingereiht.

Annahme VI:

Die Anrufer sind unendlich geduldig, was wiederum impliziert, dass kein Kunde vorzeitig auflegt, sofern er sich einmal in der Warteschlange befindet.

Annahme VII:

Da das System nur dann einen stabilen Zustand erreichen kann, wenn allgemein die Ankunftsrate der Calls kleiner als die gesamte Servicezeit der Agenten ist, wird unterstellt, dass

$$\lambda < c \cdot \mu, \quad (5.33)$$

bzw.

$$\rho = \frac{\lambda}{c \cdot \mu} < 1 \tag{5.34}$$

gilt.

Die unmittelbaren Implikationen der eben aufgeführten Annahmen sind zum einen, dass aus den Annahmen I bis IV auch die synonyme Bezeichnung des Erlang C-Modells ableiten lässt, denn in der Kendall-Notation würde dieses Modell mit exponentialverteilten Interarrival- und Servicezeiten und insgesamt c verfügbaren Agenten als *M/M/c-Modell* charakterisiert werden.

Zudem folgt aus Annahme III, dass für die Interarrival- und die Bedienzeiten gilt:

$$\lambda_n = \lambda \text{ für alle } n = 0, 1, 2, \dots \tag{5.35}$$

und

$$\mu_n = \begin{cases} n\mu & n = 0, 1, \dots, c \\ c\mu & n = c + 1, \dots \end{cases} \tag{5.36}$$

Da das Erlang C-Modell ebenfalls auf dem Geburts- und Sterbeprozess basiert, kann der hierzu korrespondierende Übergangsgraph dargestellt werden als:

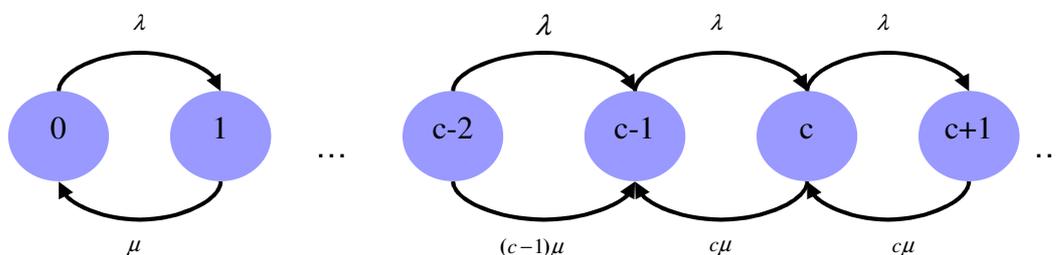


Abbildung 5.6: Übergangsgraph für das Erlang C-Modell

Hierbei wird nochmals ersichtlich, dass die Calls jeweils mit der gleichen Rate λ im Call Center eintreffen und die Agenten jeweils die gleiche Bedienzeitrate μ aufweisen, wobei sich die kollektive Bedienzeitrate jeweils durch die Anzahl der momentan beschäftigten Agenten, multipliziert mit der unterstellten Servicezeitrate, ergibt. Dies bedeutet damit auch, dass die Übergangsraten, ausgehend von einem bestimmten Systemzustand m , in den niedrigeren Zustand $(m-1)$ auf der Grundrate μ gewichtet mit dem jeweiligen Ausgangszustand m basiert. Sind alle c Agenten beschäftigt, bleibt die Übergangsrate in den niedrigeren Zustand jeweils mit $c\mu$ gleich, denn die kollektive Bearbeitungsrate kann maximal $c\mu$ betragen.

Diese Annahmen bilden die Grundlage, auf derer die interessierenden Einflussparameter „Anzahl der Anrufer in der Warteschlange“ (L_q), „Anzahl der Anrufer im Gesamtsystem“ (L_s), „Wartezeit in der Warteschlange“ (W_q) und „Wartezeit im Gesamtsystem“ (W_s) im Erlang C-Modell nun im Folgenden hergeleitet werden soll.

5.4.2 Herleitung des Erlang C-Modells

Ausgangspunkt für die Herleitung der wesentlichen Bestimmungsparameter in diesem speziellen Modell bilden die Überlegungen und festgestellten Zusammenhänge aus dem Geburts- und Sterbeprozess.¹⁷² Da nun die Zwischenankunftszeiten jeweils mit der gleichen Rate λ exponentialverteilt sind (5.35) und bei der kollektiven Bedienzeitrate eine Fallunterscheidung gemäß (5.36) beachtet werden muss, ergibt sich für C_n analog zu (5.24)

¹⁷² Vgl. hierzu und im Folgenden Gross/Harris (1985), S. 101f.; Allen (1978), S. 176f. ; Hall (1991), S. 153 f. und Gass (1996), S. 557f.

$$C_n = \begin{cases} \frac{\lambda^n}{n! \mu^n} & \text{für } n = 1, 2, \dots, c \\ \frac{\lambda^c}{c! \mu^c} \cdot \left(\frac{\lambda}{c\mu} \right)^{n-c} & \text{für } n = c + 1, c + 2, \dots \end{cases} \quad (5.37)$$

Wird an dieser Stelle auch die Definition des Arbeitsvolumens oder der Arbeitslast mit

$$a = \frac{\lambda}{\mu} \quad (5.38)$$

eingeführt, so vereinfacht sich (5.37) zu

$$C_n = \begin{cases} \frac{a^n}{n!} & \text{für } n = 1, 2, \dots, c \\ \frac{a^c}{c!} \cdot \left(\frac{a}{c} \right)^{n-c} & \text{für } n = c + 1, c + 2, \dots \end{cases} \quad (5.39)$$

Auch hier gilt es wiederum, in einem ersten Schritt die Zustandswahrscheinlichkeiten P_n zu berechnen.

Gemäß (5.25) gilt hierfür allgemein der Zusammenhang $P_n = C_n P_0$, so dass jeder beliebige Systemzustand auf Basis der Ausgangswahrscheinlichkeit, nämlich dass kein Kunde im System ist, berechnet werden kann.

Auch diese Wahrscheinlichkeit lässt sich unter Zuhilfenahme der Annahme VII ($\rho < 1$) und der Gleichung (5.26) wie folgt ableiten:

$$P_0 = \frac{1}{1 + \sum_{n=1}^{\infty} C_n} =$$

$$= \frac{1}{1 + \left[\frac{\lambda}{\mu} + \frac{\lambda\lambda}{2\mu\mu} + \frac{\lambda\lambda\lambda}{3\mu \cdot 2\mu \cdot \mu} + \mathbf{K} + \frac{\lambda^{c-1}}{\mu^{c-1}(c-1)!} + \frac{\lambda^c}{\mu^c c!} + \frac{\lambda^c}{\mu^c c!} \cdot \frac{\lambda}{\mu \cdot c} + \frac{\lambda^c}{\mu^c c!} \cdot \left(\frac{\lambda}{\mu \cdot c} \right)^2 + \Lambda \right]}$$

und mit $a = \frac{\lambda}{\mu}$ resultiert

$$\begin{aligned} P_0 &= \frac{1}{1 + \left[a + \frac{a^2}{2!} + \frac{a^3}{3!} + \mathbf{K} + \frac{a^{c-1}}{(c-1)!} + \frac{a^c}{c!} + \frac{a^c}{c!} \cdot \frac{a}{c} + \frac{a^c}{c!} \cdot \left(\frac{a}{c} \right)^2 + \Lambda \right]} \\ &= \frac{1}{\sum_{n=0}^{c-1} \frac{a^n}{n!} + \frac{a^c}{c!} \sum_{n=0}^{\infty} \left(\frac{a}{c} \right)^n} \\ &= \frac{1}{\sum_{n=0}^{c-1} \frac{a^n}{n!} + \frac{a^c}{c!} \sum_{n=0}^{\infty} \rho^n}. \end{aligned} \quad (5.40)$$

Durch Anwendung der geometrischen Reihe für $\sum_{n=0}^{\infty} \rho^n = \frac{1}{1-\rho}$, falls $|\rho| < 1$ ergibt sich dann für die Ausgangswahrscheinlichkeit

$$P_0 = \frac{1}{\sum_{n=0}^{c-1} \frac{a^n}{n!} + \frac{a^c}{c!} \frac{1}{1-\rho}}. \quad (5.41)$$

Somit lässt sich jetzt jede beliebige Zustandswahrscheinlichkeit P_n unter Verwendung von (5.25) und (5.41) berechnen:

$$P_n = \begin{cases} \frac{a^n}{n!} \cdot \frac{1}{\sum_{n=0}^{c-1} \frac{a^n}{n!} + \frac{a^c}{c!} \frac{1}{1-\rho}} & \text{für } n=0,1,\dots,c \\ \frac{a^n}{c!c^{n-c}} \cdot \frac{1}{\sum_{n=0}^{c-1} \frac{a^n}{n!} + \frac{a^c}{c!} \frac{1}{1-\rho}} & \text{für } n=c+1,\dots \end{cases} \quad (5.42)$$

Aus diesen Zustandswahrscheinlichkeiten ermitteln sich in einem weiteren Schritt analog zu (5.28) die Anzahl der Kunden in der Warteschlange L_q gemäß:

$$\begin{aligned} L_q &= \sum_{n=c}^{\infty} (n-c) \cdot P_n = \sum_{j=0}^{\infty} j \cdot P_{c+j} = \\ &= \sum_{j=0}^{\infty} j \cdot \frac{a^c}{c!} \left(\frac{a}{c}\right)^j \cdot P_0 = \frac{a^c}{c!} \cdot P_0 \cdot \sum_{j=0}^{\infty} j \cdot \left(\frac{a}{c}\right)^j = \\ &= \frac{a^c}{c!} \cdot P_0 \cdot \left(\frac{a}{c}\right) \cdot \sum_{j=0}^{\infty} \frac{d}{d} \cdot \left(\frac{a}{c}\right)^j = \frac{a^c}{c!} \cdot P_0 \cdot \left(\frac{a}{c}\right) \cdot \frac{d}{d} \cdot \sum_{j=0}^{\infty} \left(\frac{a}{c}\right)^j = \\ &= \overset{\text{geometr. Reihe}}{\frac{a^c}{c!} \cdot P_0 \cdot \left(\frac{a}{c}\right) \cdot \frac{d}{d} \cdot \left(\frac{a}{c}\right) \cdot \left(\frac{1}{1-\frac{a}{c}}\right)} = \\ &= \frac{a^c}{c!} \cdot P_0 \cdot \left(\frac{a}{c}\right) \cdot \left(\frac{1}{1-\frac{a}{c}}\right)^2, \end{aligned} \quad (5.43)$$

oder mit $\rho = \frac{a}{c}$

$$L_q = \frac{a^c}{c!} \cdot P_0 \cdot \rho \cdot \left(\frac{1}{1-\rho} \right)^2 = \frac{a^c \cdot P_0 \cdot \rho}{c!(1-\rho)^2}. \quad (5.44)$$

Aus Little's Formel $L_q = \lambda W_q$ folgt für die Wartezeit in der Warteschlange:

$$W_q = \frac{L_q}{\lambda} = \frac{a^c \cdot P_0 \cdot \rho}{c!(1-\rho)^2 \cdot \lambda}. \quad (5.45)$$

Die Wartezeit im Gesamtsystem, die sich aus der Wartezeit in der Warteschleife und der Servicezeit ($\frac{1}{\mu}$) ermitteln lässt, berechnet sich aus

$$W_s = W_q + \left(\frac{1}{\mu} \right) = \frac{a^c \cdot P_0 \cdot \rho}{c!(1-\rho)^2 \cdot \lambda} + \left(\frac{1}{\mu} \right), \quad (5.46)$$

und sofern darauf aufbauend wiederum Little's Formel zur Berechnung der Anzahl der Kunden im Gesamtsystem angewendet wird, ergibt sich L_s über

$$L_s = \lambda W_s = \lambda \cdot \left(\frac{a^c \cdot P_0 \cdot \rho}{c!(1-\rho)^2 \cdot \lambda} + \left(\frac{1}{\mu} \right) \right) = \frac{a^c \cdot P_0 \cdot \rho}{c!(1-\rho)^2} + \left(\frac{\lambda}{\mu} \right). \quad (5.47)$$

Von weiterem Interesse ist im Folgenden allerdings die Wahrscheinlichkeitsverteilung der Wartezeit eines beliebigen Kunden, da sich hieraus letztendlich auch die optimale Anzahl an Agenten ableiten lässt, wenn ein Anrufer nicht länger als eine bestimmte Anzahl an Sekunden in der Warteschleife ausharren soll.

Dazu wird zusätzlich die Prämisse eingeführt, dass die Anrufer in der Warteschlange nach dem *First-In-First-Out-Prinzip* bearbeitet werden. Des Weiteren wird eine Zufallsvariable T_q definiert, die die Wartezeit eines beliebigen, neu eintreffenden

Anrufer in der Warteschlange angibt und mit $W_q(t)$ soll im Folgenden deren Wahrscheinlichkeitsfunktion repräsentiert werden.

Somit beschreibt $W_q(0)$ die Wahrscheinlichkeit, dass die Wartezeit in der Warteschlange für einen beliebig ankommenden Kunden Null beträgt, d. h. er wird nicht erst in die Warteschlange gestellt. Berechnet wird diese Wahrscheinlichkeit über

$$\begin{aligned}
 W_q(0) &= P\{T_q = 0\} = P\{\text{"es sind weniger als } c \text{ Kunden im System"}\} = \\
 &= \sum_{n=0}^{c-1} P_n = P_0 \sum_{n=0}^{c-1} \frac{a^n}{n!}. \tag{5.48}
 \end{aligned}$$

Aus (5.41) resultiert dann

$$\begin{aligned}
 P_0 \cdot \left(\sum_{n=0}^{c-1} \frac{a^n}{n!} + \frac{a^c}{(1-\rho) \cdot c!} \right) &= 1 \\
 P_0 \cdot \sum_{n=0}^{c-1} \frac{a^n}{n!} + \frac{P_0 a^c}{(1-\rho) \cdot c!} &= 1
 \end{aligned}$$

und damit folgt für (5.48):

$$P_0 \cdot \sum_{n=0}^{c-1} \frac{a^n}{n!} = 1 - \frac{P_0 a^c}{(1-\rho) \cdot c!}. \tag{5.49}$$

Folglich gilt für die Wahrscheinlichkeit, dass ein Kunde nicht warten muss

$$W_q(0) = 1 - \frac{P_0 a^c}{(1-\rho) \cdot c!} = 1 - \frac{P_c}{(1-\rho)}. \tag{5.50}$$

Im Umkehrschluss ergibt sich die Wahrscheinlichkeit, dass ein Anrufer warten muss ($t > 0$) mit

$$W_q(t > 0) = 1 - W_q(0) = \frac{P_c}{1 - \rho}. \quad (5.51)$$

Dieser Zusammenhang wird auch als die Erlang C-Formel bezeichnet und postuliert damit folgende Abhängigkeiten in einem Call Center:

Sofern c Agenten im System zur Verfügung stehen und ein Arbeitsvolumen a vorliegt, muss ein ankommender Anrufer mit einer Wahrscheinlichkeit von

$$C(c, a) = \frac{a^c}{c!(1 - \rho)} \cdot P_0 = \frac{\frac{a^c}{c!}}{(1 - \rho) \left[\left(\sum_{n=0}^{c-1} \frac{a^n}{n!} \right) + \frac{a^c}{c!(1 - \rho)} \right]} \quad (5.52)$$

warten.¹⁷³

Nun hilft diese Formel allerdings nicht weiter, wenn die Wahrscheinlichkeit ermittelt werden soll, dass ein Kunde nur eine bestimmte maximale Wartezeit aufweisen darf. Hierfür bedarf es der Verteilungsfunktion der Wartezeit. Sofern bei Ankunft eines neuen Calls bereits n Kunden vor ihm im System sind und insgesamt wieder nur c Operatoren im System zur Verfügung stehen, muss der neue Kunde $(n - c + 1)$ exponentialverteilte Servicezeiten abwarten, um an die Reihe zu kommen.

Mit X_1, X_2, \dots sollen die unabhängigen Zufallsvariablen definiert werden, die die Servicezeit darstellen und die jeweils mit dem Parameter μ exponentialverteilt sind.

Insgesamt würde sich für den eben unterstellten Kunden eine Gesamtwartezeit in der Schlange aus der Summe der $(n - c + 1)$ Zufallsvariablen ergeben, wobei sich die kollektive Servicerate mit $c\mu$ berechnet.

In diesem Zusammenhang kann sich allerdings die Eigenschaft (V) der Exponentialverteilung zu Nutze gemacht werden, die besagt, dass die Summe von $(n -$

¹⁷³ Die Notation $C(c, a)$ wird in diesem Zusammenhang synonym für die Wahrscheinlichkeit, dass ein Kunde in die Warteschlange gestellt wird, verwendet und soll dabei zum Ausdruck bringen, dass die Wahrscheinlichkeitsberechnung auf Basis des Erlang C-Modells erfolgt.

$c+1$) exponentialverteilten Zufallsvariablen und dem Verteilungsparameter $c\mu$, einer Gammaverteilung mit den Parametern $(n-c+1)$ und $c\mu$ folgt.

Damit gilt für die Wahrscheinlichkeit, dass ein Kunde in der Warteschlange warten muss:

$$\begin{aligned}
 W_q(t) &= \sum_{n=0}^{\infty} P_n \cdot P\left\{\sum_{i=1}^n X_i > t\right\} = W_q(0) + \sum_{n=c}^{\infty} P_n \cdot P\left\{\sum_{i=1}^n X_i \leq t\right\} = \\
 &= W_q(0) + \sum_{n=c}^{\infty} P_0 \cdot \frac{a^n}{c!c^{n-c}} \cdot \int_0^t \frac{c\mu(c\mu x)^{n-c}}{\Gamma(n-c+1)} \cdot e^{-c\mu x} dx = \\
 &= W_q(0) + \sum_{n=c}^{\infty} P_0 \cdot \frac{a^n}{c!c^{n-c}} \cdot \int_0^t \frac{c\mu(c\mu x)^{n-c}}{(n-c)!} \cdot e^{-c\mu x} dx = \\
 &= W_q(0) + \sum_{n=c}^{\infty} P_0 \cdot \frac{a^c \cdot a^{n-c} \cdot c^{n-c} \cdot c}{c!c^{n-c}} \cdot \int_0^t \frac{\mu(\mu x)^{n-c}}{(n-c)!} \cdot e^{-c\mu x} dx = \\
 &= W_q(0) + P_0 \cdot \frac{a^c}{(c-1)!} \cdot \int_0^t \mu e^{-c\mu x} \left(\sum_{n=c}^{\infty} \frac{(a\mu x)^{n-c}}{(n-c)!} \right) dx.
 \end{aligned}$$

Die besondere Reihe $\sum_{n=c}^{\infty} \frac{(a\mu x)^{n-c}}{(n-c)!}$ kann aufgelöst werden in $e^{a\mu x}$, so dass gilt

$$\begin{aligned}
 W_q(t) &= W_q(0) + P_0 \cdot \frac{a^c}{(c-1)!} \cdot \int_0^t \mu e^{-c\mu x} \cdot e^{a\mu x} dx = \\
 &= W_q(0) + P_0 \cdot \frac{a^c}{(c-1)!} \cdot \int_0^t \mu e^{-\mu x(c-a)} dx = \\
 &= W_q(0) + P_0 \cdot \frac{a^c}{(c-1)!} \cdot \frac{1}{(c-a)} \left[e^{-\mu x(c-a)} \right]_0^t =
 \end{aligned}$$

$$\begin{aligned}
&= W_q(0) + P_0 \cdot \frac{a^c}{(c-1)!} \cdot \frac{1}{(c-a)} (1 - e^{-\mu(c-a)t}) = \\
&= \left(1 - \frac{P_0 a^c}{(1-\rho)c!}\right) + \frac{P_0 a^c}{(c-1)!} \cdot \frac{1}{(c-a)} (1 - e^{-\mu(c-a)t}) = \\
&= 1 - \frac{P_0 a^c}{(c-1)!} \cdot \frac{1}{(c-a)} e^{-\mu(c-a)t} = \\
W_q(t) &= 1 - C(c, a) e^{-\mu(c-a)t}. \tag{5.53}
\end{aligned}$$

Diese Wahrscheinlichkeit ist die zentrale Formel in der Personaleinsatzplanung, da in Abhängigkeit der c eingesetzten Agenten und der Arbeitslast a (in der wiederum die Servicezeitraten μ und Ankunftsrate λ enthalten sind) die Wahrscheinlichkeit für die Wartezeit t eines beliebig ankommenden Kunden berechnet werden kann. Sofern ein bestimmter Servicelevel definiert wird, der besagt, dass jeder Kunde maximal t Zeiteinheiten in der Warteschlange verbringen darf, kann dann in Abhängigkeit der Anruflast und der Servicezeiten eine optimale Anzahl an Agenten berechnet werden.

Der Vollständigkeit halber soll an dieser Stelle noch die Wahrscheinlichkeit dafür angegeben werden, dass ein neu eintreffender Kunde insgesamt maximal t Zeiteinheiten im Gesamtsystem verbringt:¹⁷⁴

$$W_s(t) = 1 + \frac{(a - c + W_q(0))}{c - 1 - a} e^{-\mu t} + \frac{C(c, a)}{c - 1 - a} e^{-c\mu(1-\rho)t} \quad \text{für } a \neq c - 1 \tag{5.53a}$$

und

$$W_s(t) = 1 + (1 + C(c, a)\mu)t e^{-\mu t} \quad \text{für } a = c - 1. \tag{5.53b}$$

¹⁷⁴ Auf einen ausführlichen Beweis wird hier verzichtet und stattdessen auf die einschlägige Literatur (z. B. siehe Allen (1978), S. 179) verwiesen.

Allerdings spielte diese Wartezeitverteilung nur eine untergeordnete Rolle, da das Hauptaugenmerk schon allein aus Kundensicht auch auf der Wartezeit in der Warteschlange liegt.

Die zentralen Einflussparameter und Kenngrößen, die bereits im Zuge des Geburts- und Sterbeprozesses allgemein hergeleitet wurden, sind nun also durch das M/M/c-Modell weiter spezifiziert und damit für einen praktischen Einsatz aufbereitet worden. Jedoch gilt es nun die Anwendungsmöglichkeiten kritisch zu hinterfragen und auf Praxistauglichkeit zu prüfen.

5.4.3 Kritische Würdigung

Das Erlang C-Modell ist sicherlich nicht ohne Grund das zentrale Modell zur Planung des Personaleinsatzes in Call Centern. Ausschlaggebend hierfür ist zum einen die Berücksichtigung eines zufallsbedingten Anrufeingangs, was der Realität viel mehr entspricht, als die Annahme eines gleichmäßigen Anfalls.

Darüber hinaus wird die Funktion der Warteschlange konkret miteinbezogen, wodurch die Wechselwirkungen zwischen Anruflast, Servicelevel und benötigten Agenten in idealer Weise abgebildet werden kann. Die einfache Handhabungsmöglichkeit durch das unterstellte Annahmesystem ist ebenfalls als positiver Aspekt herauszustellen, zumal dadurch eine leichte Implementierung in Softwaresysteme ermöglicht wird und damit eine Integration in bereits bestehende Softwareapplikationen realisiert werden kann.

Allerdings stehen diesen Vorteilen des M/M/c-Modells auch eine Reihe von negativen Aspekten gegenüber, die eine Rechtfertigung für den praktischen Einsatz eher skeptisch stimmen lassen.

So sind zum einen keine aufgelegten Anrufe vorgesehen, was eine unendliche Geduld der Kunden voraussetzt. Diese Tatsache ist allerdings aus praktischer Hinsicht unrealistisch, zumal kein Anrufer beliebig lange warten wird, bis er zu einem Operator durchgestellt wird, sondern er wird nach einer gewissen Wartezeit

auflegen. Dabei hängt diese Wartezeit von der Geduld des Anrufers ab. Problematisch ist dabei, dass im Mittel tatsächlich weniger Kunden im System sind als im Modell unterstellt wird und die Warteschlange sich dadurch von alleine abbauen und folglich der Personalbedarf tendenziell überschätzt wird. Dies geschieht umso mehr, je ungeduldiger die Anrufer sind.

Oft muss zudem davon ausgegangen werden, dass die Warteschlange nicht unendlich groß ist, weil die Leitungskapazität nicht ausreicht. Je weniger Leitungen also zur Verfügung stehen, umso mehr Anrufer werden ein Besetzzeichen erhalten, was einem Blocken gleich kommt. Auch damit wird im Modell die Anzahl wartender Kunden überschätzt und wiederum ein zu großer Agentenaufwand ausgewiesen.

Des Weiteren wird von stationären Parametern ausgegangen, d.h. es wird unterstellt, dass sowohl die Ankunftsrate λ , als auch die Servicezeiten μ im Zeitablauf keinerlei Schwankungen unterliegen. Auch diese Annahme erscheint bereits auf dem ersten Blick als völlig unrealistisch, vor allem wenn die in Kapitel 4.1 bereits nachgewiesenen Peaks im Anrufvolumen berücksichtigt werden, was zumindest auf eine zeitliche Abhängigkeit der Ankunftsrate schließen lässt. Auf diese Problematik wird auch in Kapitel 6.1 nochmals eingegangen und ist dort Gegenstand einer detaillierten Analyse.

Auch die Annahmen bezüglich der Verteilungen der Interarrivalzeiten, wie auch der Servicezeiten, sind nicht unproblematisch. Zwar ermöglicht die unterstellte Exponentialverteilung eine einfachere Berechnung der entsprechenden Wartezeitverteilungen, allerdings ist fraglich, ob diese Verteilungsannahme in der Praxis auch statistisch haltbar ist. Sofern dies in der Realität nämlich nicht zutrifft, stellt sich die Frage, wie groß die Auswirkung der tatsächlichen Verteilung auf die Ergebnisse der Personaleinsatzplanung ist und wie groß demnach die Verzerrung der tatsächlichen Zusammenhänge durch das Erlang C-Modell ist.

Auch dieser Aspekt wird Gegenstand weiterer Analysen in Kapitel 6 sein.

Zudem muss als weiterer negativer Aspekt fest gehalten werden, dass keinerlei Pausenzeiten in diesem Modell berücksichtigt werden. Auch dies ist eine äußerst

unrealistische Annahme, zumal Pausen gesetzlich vorgeschrieben sind und damit Bestandteil der Personaleinsatzplanung sein müssen.

Kapitel 6: Modifikation und Erweiterung des Erlang C Modells – Eine Simulationsstudie

Im vorangegangenen Kapitel wurde das Erlang C-Modell aus theoretischer Sicht dargestellt. In diesem Kapitel sollen nun die praktischen Aspekte näher analysiert werden, insbesondere soll hierbei zunächst das Augenmerk auf die Erfüllung der Anwendungsvoraussetzungen gelenkt werden und im weiteren Verlauf dann auf die Modifikation des M/M/c-Modells.

Um festzustellen, ob auch unter realen Bedingungen das Annahmensystem Gültigkeit besitzt, soll lediglich ein Ausschnitt aus den zur Verfügung stehenden Daten analysiert werden. Die Wahl fiel dabei auf den Monat September 2004, da für diesen Zeitraum zum einen die Datensätze vollständig vorliegen und dieser Monat erfahrungsgemäß ein sehr repräsentativer Monat ist, in dem keine Verzerrungen durch nicht-bundeseinheitliche Feiertage auftreten. Damit bietet er eine solide Basis für unverfälschte Anrufdaten.

Im Anschluss werden die Interarrival- und die Servicezeiten detaillierter untersucht, um Aufschluss über das Vorliegen oder Nichtvorliegen der Anwendungsvoraussetzungen zu erhalten.

6.1 Analyse der Ankunftszeiten

Die Annahmen, die die Ankunftszeiten betreffen, besagen zum einen, dass die Anrufe voneinander unabhängig und konstant sind und zum anderen die Zeitabstände zwischen zwei Calls exponentialverteilt sein sollen.

Diese drei Aspekte werden im Folgenden anhand der vorliegenden empirischen Daten überprüft.

6.1.1 Überprüfung homogener Poisson-Prozesse

Wie bereits mehrfach erwähnt, unterstellt das M/M/c-Modell, dass die Anrufeingänge im Call Center einem homogenen Poisson-Prozess folgen und damit unabhängig von der Zeit sind. Dies würde folglich auch bedeuten, dass die Ankunftsrate λ konstant ist. Führt man sich allerdings den Verlauf des Callvolumens über einen beliebigen Tag nochmals vor Augen (Abbildung 4.3), so ist dies in der Praxis nicht der Fall. Eindrucksvoll zeigt sich diese Tatsache auch, wenn der Tagesverlauf in 96 gleich große Zeitintervalle von jeweils 15 Minuten eingeteilt wird und die dazugehörigen absoluten Anrufeingänge in den entsprechenden Einheiten festgestellt werden. Folglich können über den gesamten Tagesverlauf hinweg die kumulierten relativen Häufigkeiten bezüglich der 96 Zeitintervalle berechnet werden (vgl. hierzu Anhang A3.1).

Sofern von gleichmäßigen Anrufeingängen ausgegangen wird, müssten sich die realen kumulierten relativen Häufigkeiten gleichmäßig über die 96 Intervalle aufteilen, was in untenstehender Grafik bedeuten würde, dass sich die rote Linie entlang der Winkelhalbierenden entwickeln muss.

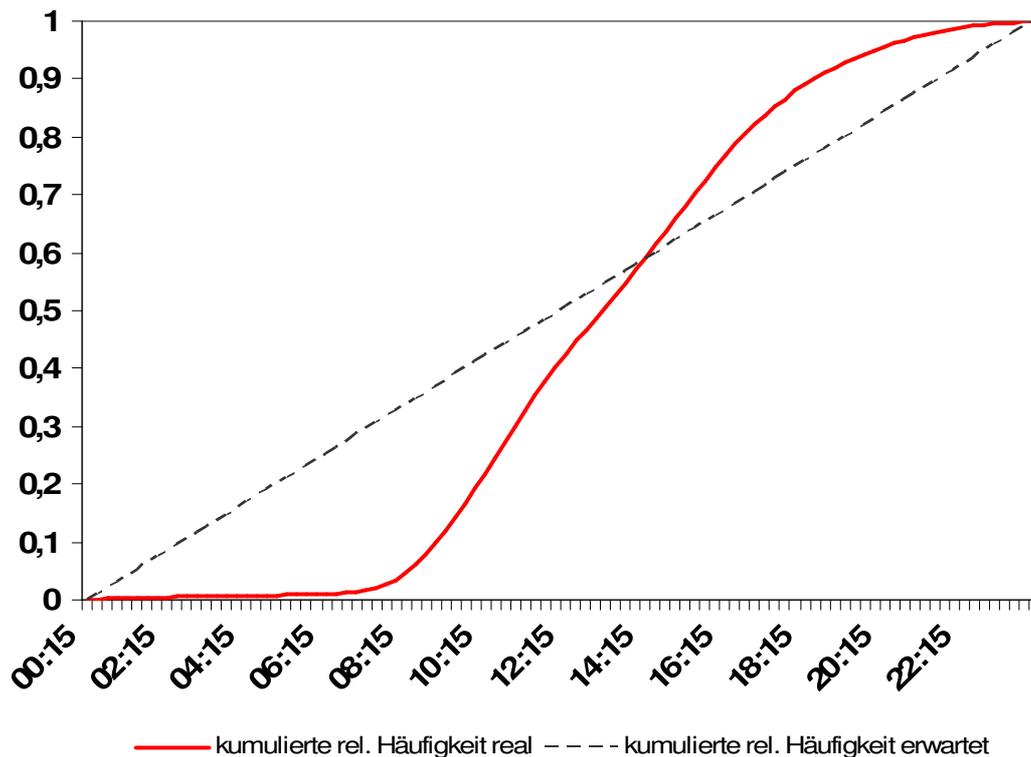


Diagramm 6.1: Gleichverteilungsplot der kumulierten relativen Häufigkeiten

Wie hier deutlich wird, ist dies nicht der Fall. Die tatsächlichen kumulierten relativen Häufigkeiten weichen deutlich von den erwarteten Häufigkeiten im Tagesverlauf ab, so dass bereits deskriptiv der Verdacht bestätigt wird, dass in realen Call Centern kein homogener Poisson-Prozess vorliegt.

Der statistische Beweis, der diese Behauptung stützen soll, wird durch Anwendung des χ^2 -Homogenitätstest erbracht.

Dazu wird das Zeitfenster weiter verengt, nämlich auf den Bereich von 8:00 bis 11:00 Uhr, so dass im Folgenden 12 Zeitintervalle betrachtet werden. Die Wahl fiel deshalb auf dieses Zeitfenster, da sich hier die größte Dynamik in den Ankunftsdaten gezeigt hat und darum eine punktuelle Analyse auf Homogenität sinnvoll erscheint.

Insgesamt gingen in diesem gesamten Zeitintervall 5384 Anrufe ein. Bei Annahme eines stationären Prozesses, müssten sich diese Anrufe gleichmäßig auf die 12 Einheiten aufteilen und damit in jedem Intervall 448,67 (theoretische) Calls

aufzutreten. Die Nullhypothese wird beim χ^2 -Test stets positiv formuliert mit H_0 : „Es liegt eine Gleichverteilung bezüglich der Anzahl der eingegangenen Anrufe je 15-Minuten-Intervall vor“. Diese Aussage würde äquivalent zur Behauptung „Der Poisson-Prozess ist homogen“ sein. Zur Überprüfung der Hypothese werden nun die empirischen Häufigkeiten mit den theoretischen Häufigkeiten verglichen und auf deren Grundlage der entsprechende χ^2 -Koeffizient berechnet.

| Zeitintervall | emp. Häufigkeit | theoret. Häufigkeit | Chi-Quadrat |
|---------------|-----------------|---------------------|--------------------|
| 08:15 | 245 | 448,6666667 | 92,45195641 |
| 08:30 | 291 | 448,6666667 | 55,40589401 |
| 08:45 | 331 | 448,6666667 | 30,85908866 |
| 09:00 | 418 | 448,6666667 | 2,096087172 |
| 09:15 | 441 | 448,6666667 | 0,131005448 |
| 09:30 | 479 | 448,6666667 | 2,050767707 |
| 09:45 | 504 | 448,6666667 | 6,824170381 |
| 10:00 | 536 | 448,6666667 | 16,99950471 |
| 10:15 | 507 | 448,6666667 | 7,584200099 |
| 10:30 | 551 | 448,6666667 | 23,34051511 |
| 10:45 | 564 | 448,6666667 | 29,64735017 |
| 11:00 | 517 | 448,6666667 | 10,40737989 |
| | 5384 | 5384 | 277,7979198 |
| | | Signifikanz | 4,1156E-53 |

Tabelle 6.1: χ^2 -Test

Der ermittelte χ^2 -Koeffizient in Höhe von 277,798 entspricht einer Signifikanz von fast 0%, so dass die Ausgangshypothese abgelehnt werden kann und damit auch der statistische Beweis erbracht ist, dass die Ankunftsrate nicht stationär sind, sondern im Zeitablauf variieren.

6.1.2 Test auf stochastische Unabhängigkeit

Als weitere Anforderung an die Ankunftsdaten wird die Tatsache gestellt, dass die Anrufe unabhängig voneinander eintreffen. Dies bedeutet, dass die Calleingänge zufällig sind.

Auch dieser Umstand kann zunächst wieder grafisch überprüft werden.

Dazu werden in einem ersten Schritt alle Zeiten zwischen zwei Anrufen ($\{T_i\}$ mit $i=2, \dots, N$) grafisch gegen ihre zeitlichen Vorgänger ($\{T_{i-1}\}$) geplottet. Sofern im dabei entstehenden Scatterplot keine Muster erkennbar sind, kann davon ausgegangen werden, dass die Interarrivalzeiten nicht voneinander abhängig sind.

Hierfür wird aus Gründen der besseren Übersicht lediglich ein Ausschnitt aus dem gesamten, für die Analyse zur Verfügung stehenden Datensatz präsentiert. Dabei ergibt sich für den Tagesdatensatz folgendes Streudiagramm:

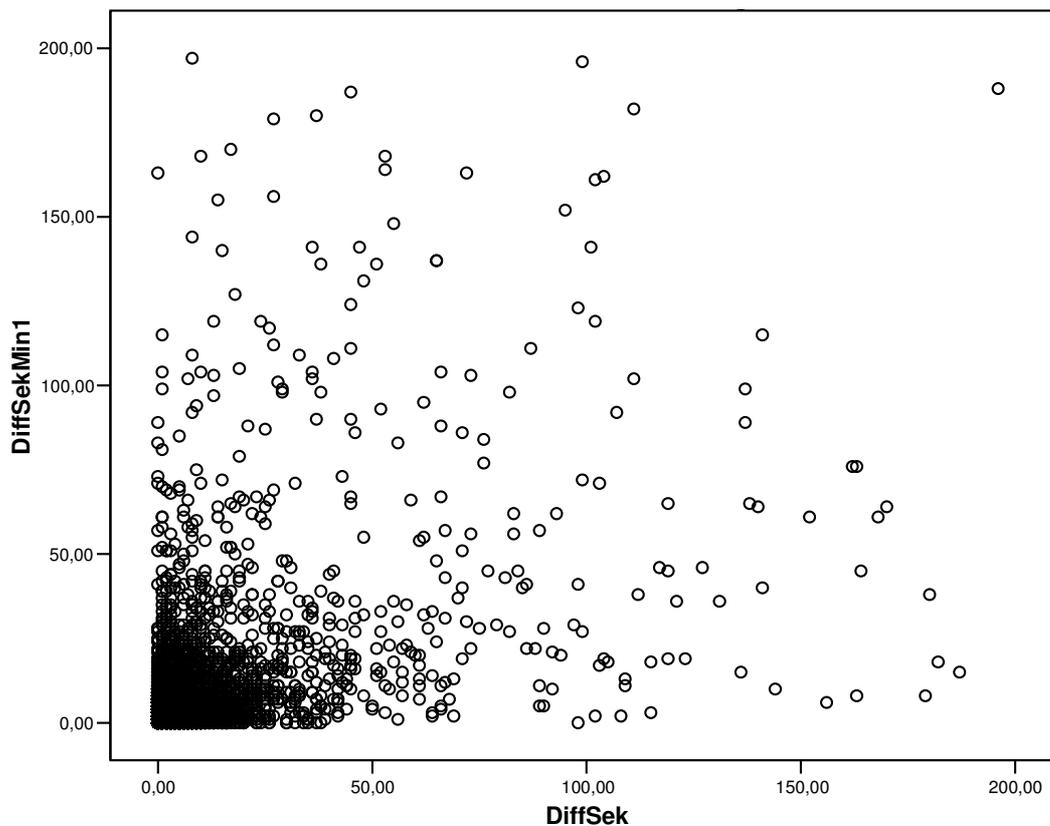


Diagramm 6.2: Streudiagramm zur Überprüfung der Unabhängigkeit der Interarrivalzeiten

Obige Darstellung zeigt, dass die Punktwolke aus den Tupeln ($\{T_i\}; \{T_{i-1}\}$) kein Muster erkennen lässt und damit ein erstes Indiz für unabhängige Anrufeingänge gegeben ist. Die statistische Absicherung hierfür wird durch den t-Test für eine Stichprobenkorrelation geschehen. Die Nullhypothese hierfür lautet:

H_0 : “Es besteht kein Zusammenhang zwischen $\{T_i\}$ und $\{T_{i-1}\}$ “.

Der Test basiert dabei auf dem Korrelationskoeffizienten zwischen $\{T_i\}$ und $\{T_{i-1}\}$, der aus der Stichprobe ermittelt wird.

Für den vorliegenden Datensatz ergibt sich dabei ein Koeffizient von 0,495, der gemäß unten stehendem SPSS-Ausdruck auch signifikant ist.¹⁷⁵

| | | DiffSek | DiffSekMin1 |
|-------------|--------------------------|---------|-------------|
| DiffSek | Korrelation nach Pearson | 1 | ,495** |
| | Signifikanz (2-seitig) | | ,000 |
| | N | 20096 | 19865 |
| DiffSekMin1 | Korrelation nach Pearson | ,495** | 1 |
| | Signifikanz (2-seitig) | ,000 | |
| | N | 19865 | 20096 |

** Die Korrelation ist auf dem Niveau von 0,01 (2-seitig) signifikant.

Tabelle 6.2: Korrelation zwischen $\{T_i\}$ und $\{T_{i-1}\}$ (Tagesbasis)

Übertragen auf die Calldaten würde dies bedeuten, dass durchaus ein Zusammenhang zwischen den Interarrivalzeiten besteht. Allerdings ist dabei zu beachten, dass zwischen den Zeiten tagsüber und nachts unterschieden werden muss, denn nachts erfolgen die Anrufe verständlicherweise in insgesamt längeren Zeitabständen, während tagsüber die Taktung kürzer ist. Diese Tatsache wirkt sich auch auf den Korrelationskoeffizienten aus, zumal tagsüber einem wertmäßig kleinem $\{T_{i-1}\}$ auch ein wertmäßig kleines $\{T_i\}$ folgt, während in den Nachtstunden genau der umgekehrte Zusammenhang gilt. Da in obigem Beispiel der gesamte Tagesverlauf in

¹⁷⁵ In den SPSS-Outputs wird die Variable $\{T_i\}$ mit „DiffSek“ und die Variable $\{T_{i-1}\}$ entsprechend mit „DiffSekMin1“ bezeichnet.

die Berechnung einging, wirkt sich dieser Tag/Nacht-Einfluss auch auf den Korrelationskoeffizienten aus, der hierin einen Zusammenhang sieht und dadurch den Koeffizienten in Höhe von 0,495 ausgibt. Wird aber auf kleinere Zeitintervalle übergegangen, in denen die mittlere Ankunftsrate jeweils annähernd konstant ist, kann der oben beschriebene Einfluss dynamischer Ankunftsraten ausgeschaltet werden und es ergibt sich ein anderes Bild.

Der Korrelationskoeffizient des Zeitfensters von 10:00 bis 12:00 Uhr etwa nimmt einen Wert von -0,007 an.

Korrelationen

| | | DiffSek | DiffSekMin1 |
|-------------|--------------------------|---------|-------------|
| DiffSek | Korrelation nach Pearson | 1 | -,007 |
| | Signifikanz (2-seitig) | | ,665 |
| | N | 4181 | 4118 |
| DiffSekMin1 | Korrelation nach Pearson | -,007 | 1 |
| | Signifikanz (2-seitig) | ,665 | |
| | N | 4118 | 4181 |

Tabelle. 6.3: Korrelation zwischen $\{T_i\}$ und $\{T_{i-1}\}$ (10:00 bis 12:00 Uhr)

In diesem Fall kann der t-Test bei einem Signifikanzniveau von 0,665 nicht mehr abgelehnt werden, was wiederum bedeutet, dass kein Zusammenhang zwischen $\{T_i\}$ und $\{T_{i-1}\}$ statistisch nachweisbar ist. Sogar im Zeitfenster von 8:00 bis 12:00 Uhr resultiert nur ein Korrelationskoeffizient von 0,015, der wiederum keinen signifikanten Zusammenhang zwischen den Interarrivalzeiten erkennen lässt:

Korrelationen

| | | DiffSek | DiffSekMin1 |
|-------------|--------------------------|---------|-------------|
| DiffSek | Korrelation nach Pearson | 1 | ,015 |
| | Signifikanz (2-seitig) | | ,189 |
| | N | 7387 | 7285 |
| DiffSekMin1 | Korrelation nach Pearson | ,015 | 1 |
| | Signifikanz (2-seitig) | ,189 | |
| | N | 7285 | 7387 |

Tabelle 6.4: Korrelation zwischen $\{T_i\}$ und $\{T_{i-1}\}$ (8:00 bis 12:00 Uhr)

Somit kann die Annahme zufälliger Anrufeingänge in der Praxis bestätigt werden.

6.1.3 Überprüfung der Verteilungsannahme

Die letzte entscheidende Annahme bezüglich der Arrivalzeiten besagt, dass die Zeit zwischen zwei Calls exponentialverteilt ist.

Zur Überprüfung der Interarrivalzeiten muss der komplette Datensatz entsprechend aufbereitet werden, denn um die bereits nachgewiesenen dynamischen Effekte der Ankunftsraten auszuschalten und damit verzerrten Daten vorzubeugen, werden über den Monat September Querschnittsdaten gebildet. Dafür werden die einzelnen Tage zunächst in 24 Zeiteinheiten zu je 60 Minuten eingeteilt, um in diesen Einheiten jeweils konstante Ankunftsraten zu haben. Zudem müssen die nachgewiesenen Aspekte aus Kapitel 4.2 berücksichtigt werden, denn dort wurde bereits gezeigt, dass sich bezüglich der Anzahl der Anrufeingänge nur die Tage Dienstag, Mittwoch, Donnerstag und Freitag nicht signifikant unterscheiden und an diesen Tagen damit gleiche Callperformances vorliegen. Umgekehrt bedeutet dies aber auch, dass zur Überprüfung der Verteilung der Interarrivalzeiten eine Fallunterscheidung nötig wird, denn eine bedingungslose Miteinbeziehung aller Interarrivalzeiten unabhängig vom Wochentag, würde in einer Verzerrung der tatsächlichen Verteilung münden. Somit wird der Gesamtdatensatz nicht nur in die 24 Stundenintervalle zerlegt, sondern auch noch dahingehend unterschieden, welcher Wochentag vorliegt, wobei zwischen vier Kategorien differenziert wird: Montag, Dienstag bis Freitag, Samstag und Sonntag.

Es können dann in Abhängigkeit von den Merkmalen „Stundenintervall“ (insgesamt 24) und „Wochentagkategorie“ die entsprechenden Zwischenankunftszeiten bestimmt werden. Damit ergeben sich insgesamt 96 Kombinationsmöglichkeiten und demnach 96 verschiedene Datensätze, deren Verteilungen analysiert werden müssen. Um die Systematik zu erläutern, wird exemplarisch die Analyse der Interarrivalzeiten im Stundenintervall von 9:00 bis 10:00 Uhr in der Wochentagkategorie „Dienstag bis Freitag“ dargestellt.

Als Analysetool wird das Softwareprogramm „BestFit“¹⁷⁶ dienen, das für eine beliebige Stichprobe die jeweils beste Verteilungsanpassung findet.

¹⁷⁶ Vgl. Palisade, „BestFit“.

Im Erlang C-Modell wird generell eine Exponentialverteilung für die Zwischenankunftszeiten unterstellt, was in untenstehender Grafik der Verlauf der roten Linie entsprechen würde. Die blaue Fläche hingegen repräsentiert die Verteilung der tatsächlichen Callzeiten. Bei Einhaltung der unterstellten Verteilungsannahme, müsste sich die blaue Fläche exakt entlang der roten Linie entwickeln.

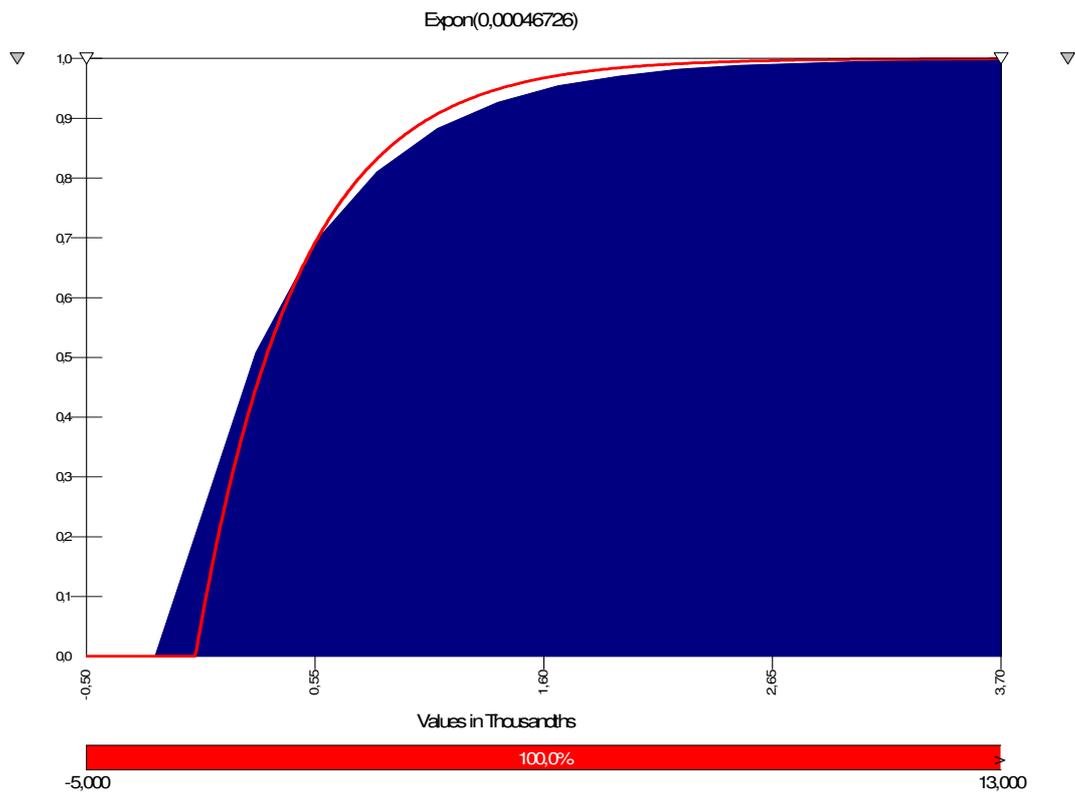


Diagramm 6.3: Verteilungsanpassung der Interarrivalzeiten durch die Exponentialverteilung

Tatsächlich zeigt sich aber, dass keine optimale Anpassung der realen Verteilung an die unterstellte Exponentialverteilung gegeben ist. In Wirklichkeit resultiert hier ein optimaler Fit durch die Gammaverteilung mit einem Formparameter $\alpha = 0,67731$ und einem Lageparameter $\beta = 0,00070964$. Diagramm 6.4 zeigt, wie gut sich die tatsächliche Stichprobenverteilung an die theoretische Gammaverteilung anpasst.

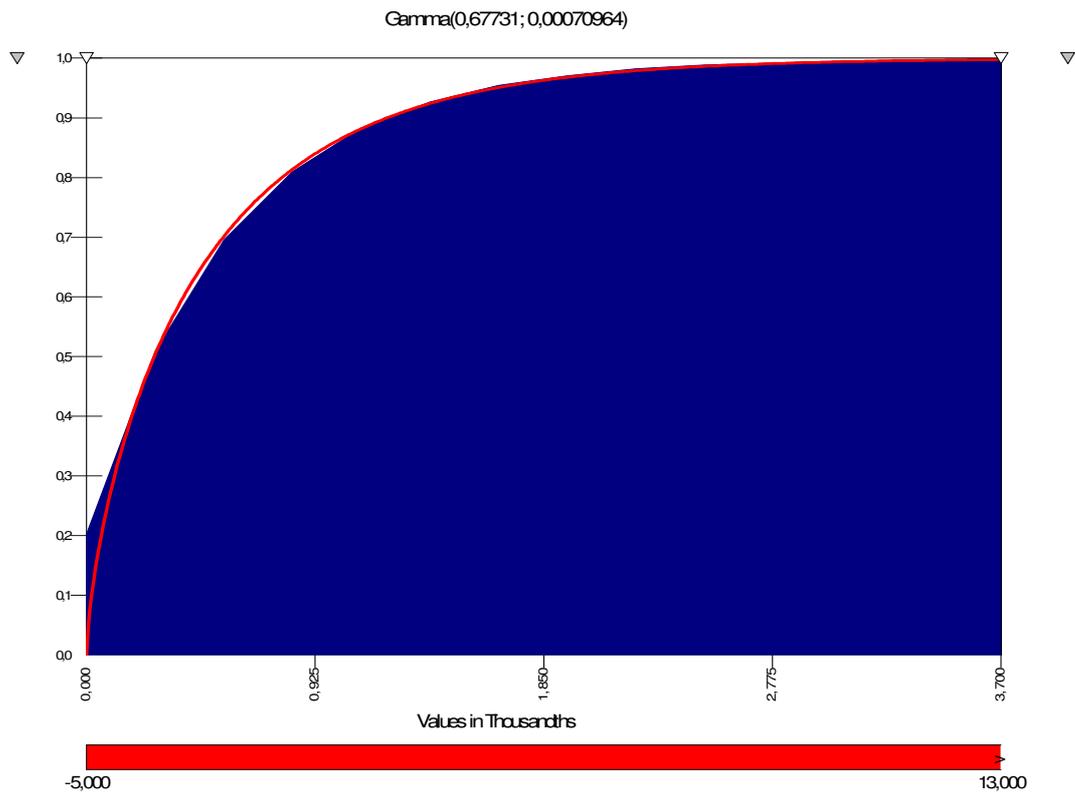


Diagramm 6.4: Verteilungsanpassung der Interarrivalzeiten durch die Gammaverteilung

Die Analyse der übrigen Datensätze der Kategorie „Dienstag bis Freitag“ ergab, dass sich die Exponentialverteilung durchwegs als suboptimale Verteilung erweist und die Gammaverteilung die tatsächliche Stichprobenverteilung stets besser abbilden kann.¹⁷⁷

Des Weiteren zeigt sich nach Abschluss der Komplettüberprüfung aller 96 Datensätze, dass meistens die Gamma-Verteilung als bester Fit resultiert. Vereinzelt wäre eine Weibull-Verteilung noch besser gewesen, allerdings sind die Unterschiede in der Anpassung stets so minimal, dass aus Gründen der Einheitlichkeit auf die Gamma-Verteilung übergegangen wird. Dies geschieht auch im Hinblick auf die Simulationsstudie, die bei tageseinheitlichen Verteilungen weniger komplex wird.

In der untenstehenden Tabelle ist nochmals ein zusammenfassender Überblick über die Ergebnisse der Verteilungsanpassungen gegeben. In der Kommentarspalte wird

¹⁷⁷ Die entsprechenden Resultate können in den BestFit Dateien auf beiliegender DVD eingesehen werden.

dabei stets der Anteil der insgesamt jeweils 24 Stichproben angegeben, in denen die Gamma-Verteilung besser ist gegenüber der Weibull-Verteilung.

| Wochentag | Verteilung | Kommentar |
|----------------------|-------------------|------------------|
| Montag | Gamma | 62,5 % |
| Dienstag bis Freitag | Gamma | 70,83% |
| Samstag | Gamma | 83,3% |
| Sonntag | Gamma | 66,67% |

Tabelle 6.5: Übersicht der Ergebnisse der Verteilungsanpassung der Interarrivalzeiten

Somit kann als Fazit festgehalten werden, dass die unterstellte Exponentialverteilung der Zwischenankunftszeiten in der Realität tatsächlich nicht gegeben ist und damit eine wesentliche Prämissenverletzung¹⁷⁸ des Erlang C-Modells vorliegt. Dieser Aspekt muss im Folgenden auch bei der Optimierung der Personaleinsatzplanung ihre Berücksichtigung finden.

6.2 Analyse der Servicezeiten

Analog zu den Zwischenankunftszeiten werden im Erlang C-Modell auch für die Servicezeiten in einem Call Center konkrete Prämissen aufgestellt.

Zum einen müssen auch hier wieder stationäre Servicezeitraten vorliegen und deren stochastische Unabhängigkeit muss abermals gegeben sein. Zudem sollten die Servicezeitraten ebenfalls einer Exponentialverteilung folgen.

¹⁷⁸ Auch wenn die Exponentialverteilung und die Gamma-Verteilung von der gleichen Verteilungsfamilie abstammen, so sind die Unterschiede dennoch entscheidend für die Anwendung des M/M/c-Modells.

6.2.1 Test auf stationäre Servicezeiten

Im ersten Schritt soll wiederum untersucht werden, ob die Gesprächszeiten im Zeitablauf konstant sind oder nicht.

In der Telekommunikationsanlage, wie sie in Kapitel 2.2 bereits dargestellt wurde, wird die Servicezeit mit „t(ab)“ bezeichnet, da in dieser Variablen die Zeitdauer gespeichert wird, in der ein Agent mit einem Kunden kommuniziert und damit beschäftigt ist.

Ein erster Eindruck über das grundsätzliche Verhalten der Servicezeiten soll eine deskriptive Beschreibung des Datensatzes hinsichtlich der Variablen „t(ab)“ geben. Dazu werden die Wochentage von September 2004 wieder in insgesamt 96 Zeitintervalle zu je 15-Minuten zerlegt und die jeweils darin aufgetretenen Servicezeiten (in Minuten) bezüglich deren Mittelwert und Varianz beschrieben.

Hierbei zeigt sich schon eine erste Auffälligkeit, denn in den Nachtstunden (20:00 bis 8:00 Uhr) variieren die Varianzen der Gesprächszeiten viel mehr als tagsüber. Während der Tagesstunden scheinen sich die Zeiten zu stabilisieren. Exemplarisch werden hier fünf Tagesverläufe in unten stehendem Diagramm abgebildet.

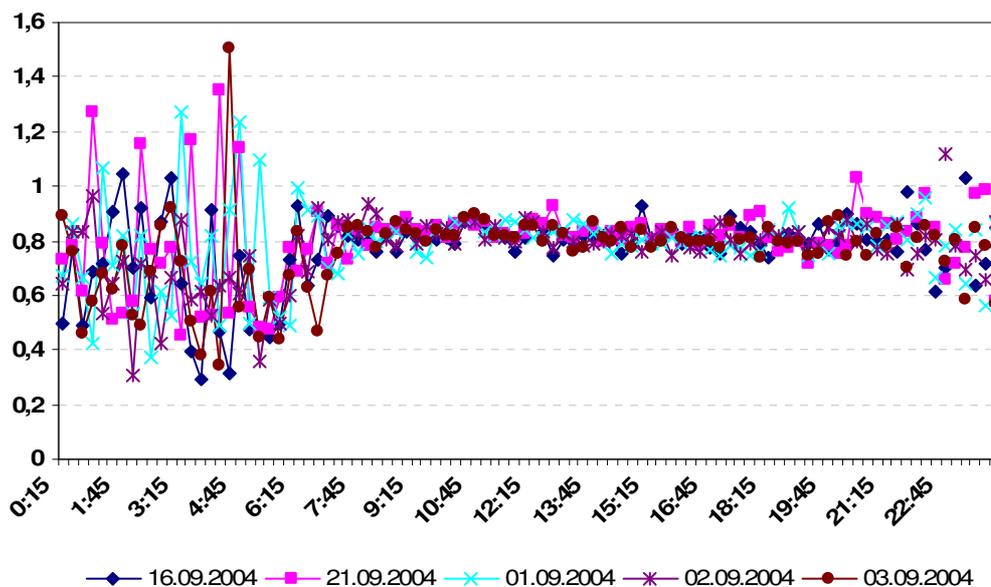


Diagramm 6.5: Varianzen der Servicezeiten im Tagesverlauf

Um diesen Anfangsverdacht von nicht stationären Servicezeiten auch statistisch abzusichern, werden die Datensätze in die beiden Kategorien „tagsüber“ und „nachts“ eingeteilt und anschließend ein Mittelwertvergleich hinsichtlich der Servicezeiten durchgeführt (Anhang A3.2.1). Hierbei zeigt sich, dass bei einem Signifikanzniveau von 5% die Hypothese, dass die mittlere Gesprächszeit tagsüber und nachts gleich ist, nicht aufrechterhalten werden kann. Insgesamt ist die mittlere Servicezeit während den Nachtstunden um 3,44 Sekunden kürzer, als zur restlichen Zeit.

Eine plausible Erklärung für dieses Ergebnis scheint auf den ersten Blick nicht zu bestehen, zumal eher der gegenteilige Effekt zu erwarten war, denn tagsüber ist eine größere Anzahl an Anrufeingängen im Call Center zu verzeichnen und die Agenten vor diesem Hintergrund auch darauf bedacht sind, die Kunden möglichst schnell abzufertigen, um das vorgegebene Servicelevel auch halten zu können. Nachts entfällt dann dieser Druck fast vollständig, was sich auch in längeren Gesprächszeiten widerspiegeln würde.

Eine eingehendere Analyse diesbezüglich zeigt, dass gerade während der Nachtstunden äußerst kurze Servicezeiten auftreten, die meistens unter zehn Sekunden liegen.

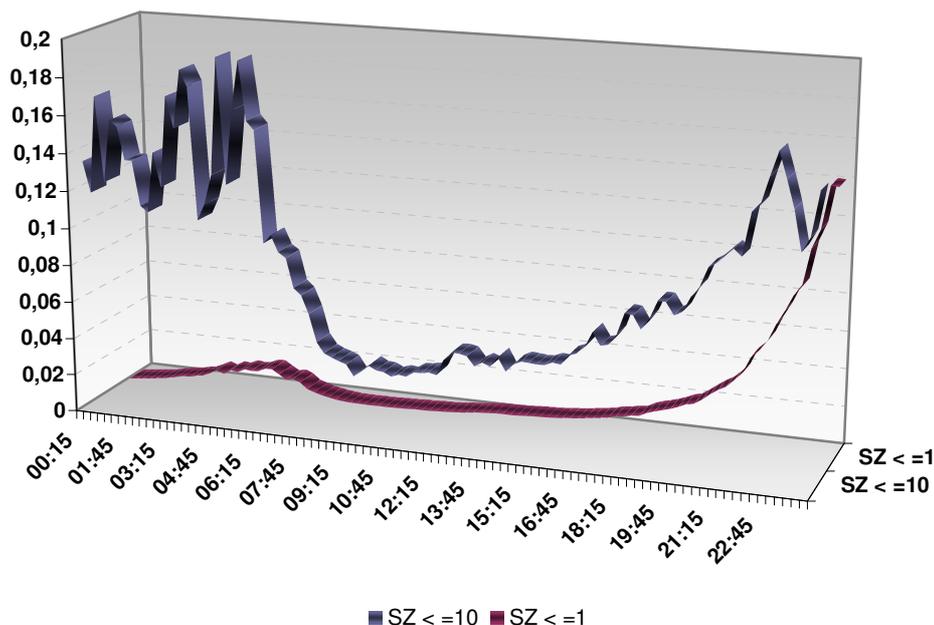


Diagramm 6.6: Anteil kleiner Servicezeiten an der Gesamthäufigkeit

Obiges Diagramm bildet den Anteil der Servicezeiten von bis zu einer Sekunde ($SZ \leq 1$) und von bis zu zehn Sekunden ($SZ \leq 10$) an der Gesamtanzahl der aufgetretenen Gesprächszeiten im Tagesablauf ab. Die extrem kurzen Gespräche treten dabei verstärkt während den Nachtstunden auf (Verlauf der roten Linie), während tagsüber deren Anteil deutlich kleiner ist. Auch die Servicezeiten von insgesamt unter zehn Sekunden weisen ein ähnliches Bild auf, denn auch hier ist nachts der Anteil wesentlich größer als zur übrigen Tageszeit.

Dieses Phänomen stellt ein allgemeines Problem in der Call Center Planung dar, da Agenten oftmals Anrufe einfach selber blocken, indem sie nach dem Abheben gleich wieder auflegen, um sich so selbst gewisse Ruhezeiten zu verschaffen. Um diese Verzerrung aus den Daten zu eliminieren, wurde eine entsprechende Selektion vorgenommen und diese unrealistischen Gesprächszeiten entfernt. Nach einem erneuten t-Test zeigt sich dann ein anderes Bild, denn die Servicezeiten in den Nachtstunden steigen wieder an und ein signifikanter Unterschied zu den Zeiten tagsüber kann schließlich nicht mehr bestätigt werden.¹⁷⁹

Von Interesse ist noch die Entwicklung der Gesprächszeiten im Tagesablauf. Bevor dies aber analysiert wird, muss noch eine zusätzliche Untersuchung dahingehend vorgeschaltet werden, ob sich die mittlere Gesprächszeit an Werktagen anders verhält, als an Wochenenden.

Diese Unterscheidung ist insbesondere auch für die spätere Simulation von Bedeutung, da im Falle unterschiedlicher Servicezeiten dieser Umstand in der Berechnungsgrundlage der Personaleinsatzplanung ihren Eingang finden muss.

Eine erste deskriptive Veranschaulichung der Mittelwertperformance der Servicezeiten an Werktagen und an Wochenenden lässt wieder vermuten, dass ein signifikanter Unterschied besteht.

¹⁷⁹ Vgl. hierzu Anhang A3.2.1.

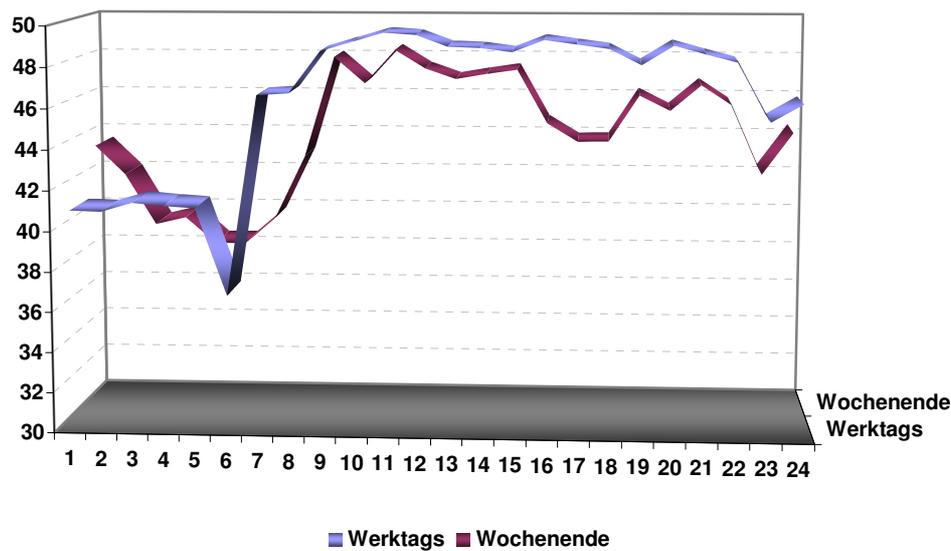


Diagramm 6.7: Verlauf der mittleren Servicezeit im Tagesablauf (Werktag / Wochenende)

Beim anschließend durchgeführten paarweisen Vergleichstest über die Mittelwerte der 24 Stundenintervalle lässt sich zusammenfassend die im Diagramm 6.8 aufgezeigte Übersichtsgrafik darstellen. Zu sehen ist hier die Entwicklung der t-Prüfstatistik im Tagesverlauf, wenn für jedes Stundenintervall jeweils ein Mittelwertsvergleich der Gesprächszeiten angesetzt wird. Die Grenzen, die für ein Signifikanzniveau von 5% berechnet werden können, sind ebenfalls im Diagramm abgebildet. Sofern die Ober- oder Untergrenze überschritten wird, ist dies jeweils durch einen roten Differenzbalken dargestellt. Gerade im Bereich von 10:00 bis letztlich 21:00 Uhr kann damit festgestellt werden, dass sich die Servicezeiten auch statistisch signifikant unterscheiden und dieser Aspekt im weiteren Verlauf der Analyse berücksichtigt werden muss, denn ab jetzt muss zusätzlich eine Differenzierung zwischen den Gesprächszeiten an Werktagen und an Wochenenden getroffen werden.

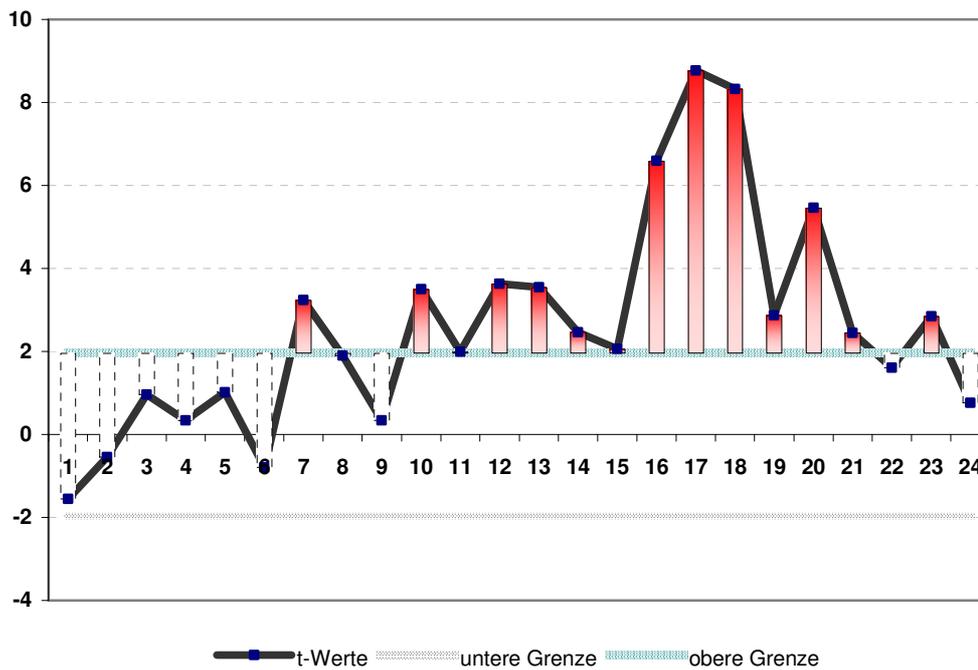


Diagramm 6.8: t-Test zur Überprüfung der Konkordanz der Servicezeiten an Werktagen und Wochenenden

Nach diesen Feststellungen kann der eigentliche Test zur Überprüfung von zeitlich unabhängigen Servicezeiten durchgeführt werden. Der statistische Beweis ist erbracht, wenn nachgewiesen werden kann, dass keine Korrelation zwischen den (hier auf Stundenbasis ermittelten) durchschnittlichen Gesprächszeiten und der Tageszeit besteht. Anhand einer Regressionsanalyse soll diese Überprüfung nun stattfinden, wobei die durchschnittliche Servicezeit als Regressand und die Tageszeit als Regressor angesehen wird. Nach Auswertung der für Werktage und Wochenenden separat durchgeführten Analysen, ergeben sich folgende Resultate:

| Stationarität Werktags | |
|-----------------------------------|-------------|
| AUSGABE: ZUSAMMENFASSUNG | |
| <i>Regressions-Statistik</i> | |
| Multipler Korrelationskoeffizient | 0,645593267 |
| Bestimmtheitsmaß | 0,416790667 |
| Adjustiertes Bestimmtheitsmaß | 0,390281151 |
| Standardfehler | 2,96694041 |
| Beobachtungen | 24 |

| ANOVA | | | | | |
|------------|---------------------|--------------------|----------------------------|---------------|-------------|
| | Freiheitsgrade (df) | Quadratsummen (SS) | Mittlere Quadratsumme (MS) | Prüfgröße (F) | F krit |
| Regression | 1 | 138,3992854 | 138,3992854 | 15,7223044 | 0,000656623 |
| Residue | 22 | 193,6601787 | 8,802735398 | | |
| Gesamt | 23 | 332,0594642 | | | |

| | Koeffizienten | Standardfehler | t-Statistik | P-Wert |
|---------------|---------------|----------------|-------------|-------------|
| Schnittpunkt | 42,05959213 | 1,250121783 | 33,64439585 | 2,05228E-20 |
| Variable Zeit | 0,346910946 | 0,0874903 | 3,965136113 | 0,000656623 |

Tabelle 6.6: Analyse der Gesprächszeitreihe an Werktagen

Für den Zeitraum von Montag bis Freitag ergibt sich also ein Einfluss der Zeitkomponente, zumal durch den Regressionsansatz hier ein signifikanter Anteil der Gesamtstreuung erklärt werden kann und damit das ausgewiesene Bestimmtheitsmaß auch auf die Grundgesamtheit übertragbar ist. Des Weiteren beweist die t-Statistik für den Regressor „Zeit“, dass dieser Einfluss in der Grundgesamtheit signifikant von Null verschieden ist und damit eine Zeitabhängigkeit der Servicezeiten an Werktagen nachgewiesen ist.

Analog wird dieselbe Regressionsanalyse auch für die Datensätze am Wochenende angesetzt, worauf sich folgendes Bild zeigt:

| Stationarität Wochenende | |
|-----------------------------------|-------------|
| AUSGABE: ZUSAMMENFASSUNG | |
| Regressions-Statistik | |
| Multipler Korrelationskoeffizient | 0,482900352 |
| Bestimmtheitsmaß | 0,23319275 |
| Adjustiertes Bestimmtheitsmaß | 0,198337875 |
| Standardfehler | 2,83952369 |
| Beobachtungen | 24 |

| ANOVA | | | | | |
|------------|---------------------|--------------------|----------------------------|---------------|------------|
| | Freiheitsgrade (df) | Quadratsummen (SS) | Mittlere Quadratsumme (MS) | Prüfgröße (F) | F krit |
| Regression | 1 | 53,94392061 | 53,94392061 | 6,690391234 | 0,01683831 |
| Residue | 22 | 177,3836853 | 8,062894789 | | |
| Gesamt | 23 | 231,327606 | | | |

| | Koeffizienten | Standardfehler | t-Statistik | P-Wert |
|--------------|---------------|----------------|-------------|-------------|
| Schnittpunkt | 41,43850777 | 1,196434686 | 34,63499366 | 1,09625E-20 |
| X Variable 1 | 0,216581987 | 0,083732985 | 2,58657906 | 0,01683831 |

Tabelle 6.7: Analyse der Gesprächszeitreihe am Wochenende

Auch hier kann bei einem Signifikanzniveau von 5% davon ausgegangen werden, dass an Wochenenden ebenfalls die Gesprächszeiten von der Uhrzeit abhängig sind.

Es gilt somit als erwiesen, dass die Servicezeiten im Tagesverlauf nicht konstant sind und damit ebenfalls eine Annahmeverletzung des Erlang C-Modells vorliegt.

Im Hinblick auf die Simulation in Kapitel 6.4 kann nachgewiesen werden, dass die Servicezeiten zumindest in den Stundenintervallen konstant sind. Der entsprechende Nachweis kann im Anhang A3.2.2 eingesehen werden. Hierzu wurden die Stundenintervalle noch weiter, in jeweils vier 15-Minuten-Bereiche aufgeteilt und die darin angefallenen durchschnittlichen Gesprächszeiten miteinander verglichen. Die Varianzanalyse zeigte dann, dass die entsprechenden Zeiten in den vier Intervallen gleich sind.

6.2.2 Überprüfung der stochastischen Unabhängigkeit

Eine weitere Forderung im Erlang C-Modell lautet, dass die Servicezeiten voneinander unabhängig sein sollen. Ein Streudiagramm vermittelt hierfür wiederum einen ersten Eindruck darüber, ob eine Systematik zwischen der Gesprächszeit in t mit der vorherigen in $(t-1)$ besteht.

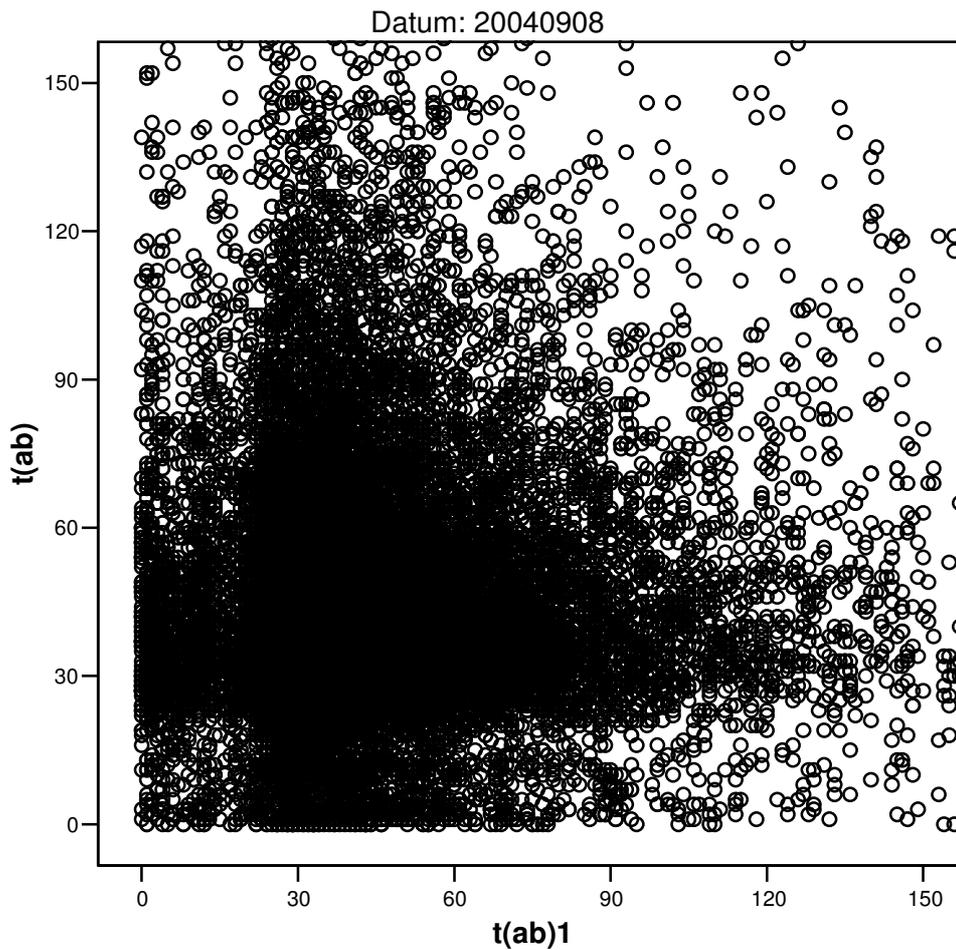


Diagramm 6.9: Streudiagramm der Gesprächszeiten

Auf den ersten Blick lassen sich hierbei keine Muster erkennen, allerdings soll der Nachweis wieder durch eine Korrelationsanalyse erbracht werden.

Korrelationsr²

| | | t(ab) | t(ab)1 |
|--------|--------------------------|-------|--------|
| t(ab) | Korrelation nach Pearson | 1 | -,003 |
| | Signifikanz (2-seitig) | | ,729 |
| | N | 19078 | 19078 |
| t(ab)1 | Korrelation nach Pearson | -,003 | 1 |
| | Signifikanz (2-seitig) | ,729 | |
| | N | 19078 | 19078 |

a. Datum = 20040908

Tabelle 6.8: Korrelationsanalyse der Gesprächszeiten

Für die obige Auswahl an Servicezeiten berechnet sich hier ein Korrelationskoeffizient in Höhe von $-0,003$ und ist gemäß des t-Tests bei einer Irrtumswahrscheinlichkeit von $0,729$ nicht signifikant.

Damit ist eine zentrale Annahme des Erlang C-Modells bezüglich der Gesprächszeiten erfüllt.

6.2.3 Überprüfung der Verteilungsannahme

Die letzte, aber wesentliche Prämisse, die die Servicezeiten betrifft, ist die der unterstellten Exponentialverteilung mit dem Parameter μ . Nachdem in Kapitel 6.2.1 schon gezeigt wurde, dass die Servicezeiten in den 24 Stundenintervallen jeweils stationär sind, ist es sinnvoller die Exponentialverteilung jeweils speziell in diesem Zeitfenster zu untersuchen. Des Weiteren muss aus Gründen der Einheitlichkeit noch die Erkenntnisse aus der Untersuchung der Interarrivalzeiten berücksichtigt werden, nämlich dass hier jeweils signifikante Unterschiede in den Verteilungsparametern zwischen den Zwischenankunftszeiten von „Dienstag bis Freitag“, „Samstag“, „Sonntag“ und „Montag“ zu beachten sind. Demnach muss auch bei den Servicezeiten eine differenzierte Überprüfung hinsichtlich der Wochentagskategorie stattfinden. Damit ergeben sich aus der Kombination von den 24 Stundenintervallen und der Wochentagskategorie analog zur Verteilungsanalyse der Interarrivalzeiten, 96 zu überprüfende Stichprobenverteilungen.

Exemplarisch sei hierbei die Verteilung der Gesprächszeiten von 12:00 bis 13:00 Uhr an den Wochentagen Dienstag bis Freitag dargestellt. Unten stehendes Diagramm zeigt durch die blaue Fläche wiederum die empirische Verteilung auf, während die rote Linie die unterstellte Exponentialverteilung ist.

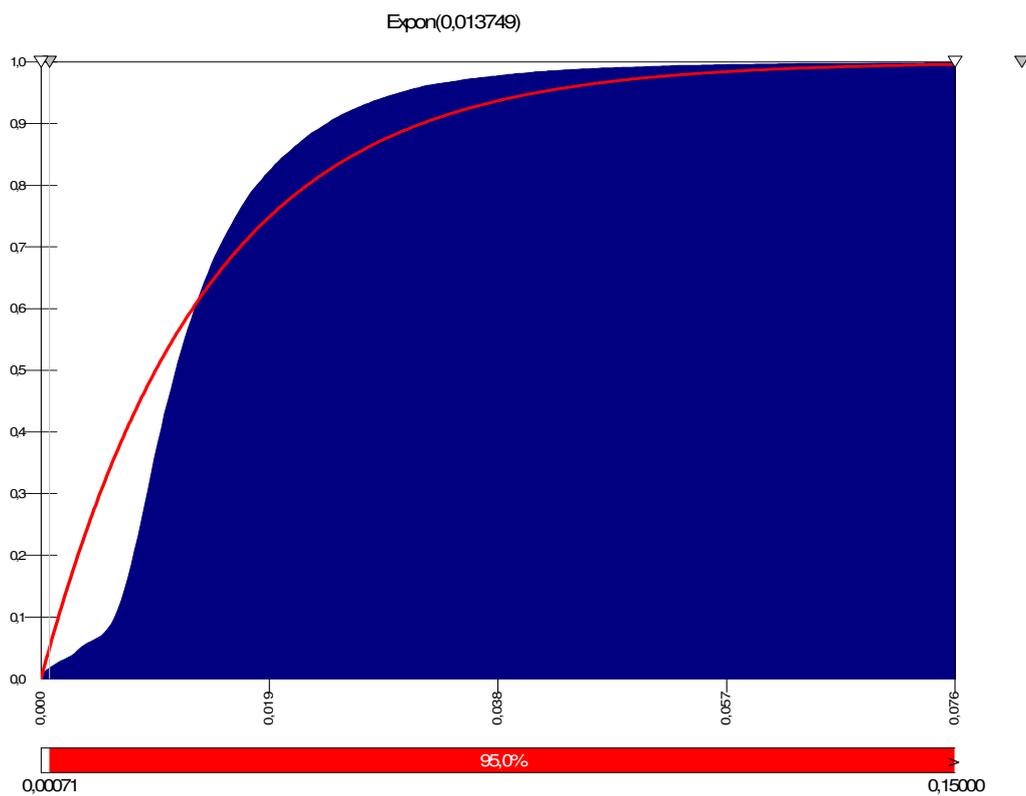


Diagramm 6.10: Verteilungsanpassung der Gesprächszeiten durch die Exponentialverteilung

Wie schon bei den Interarrivalzeiten weicht die unterstellte Exponentialverteilung erheblich von der tatsächlichen Stichprobenverteilung ab. Weitere Analysen zeigen auch hier, dass ein wesentlich besserer Fit durch die Lognormalverteilung erzielt werden kann.

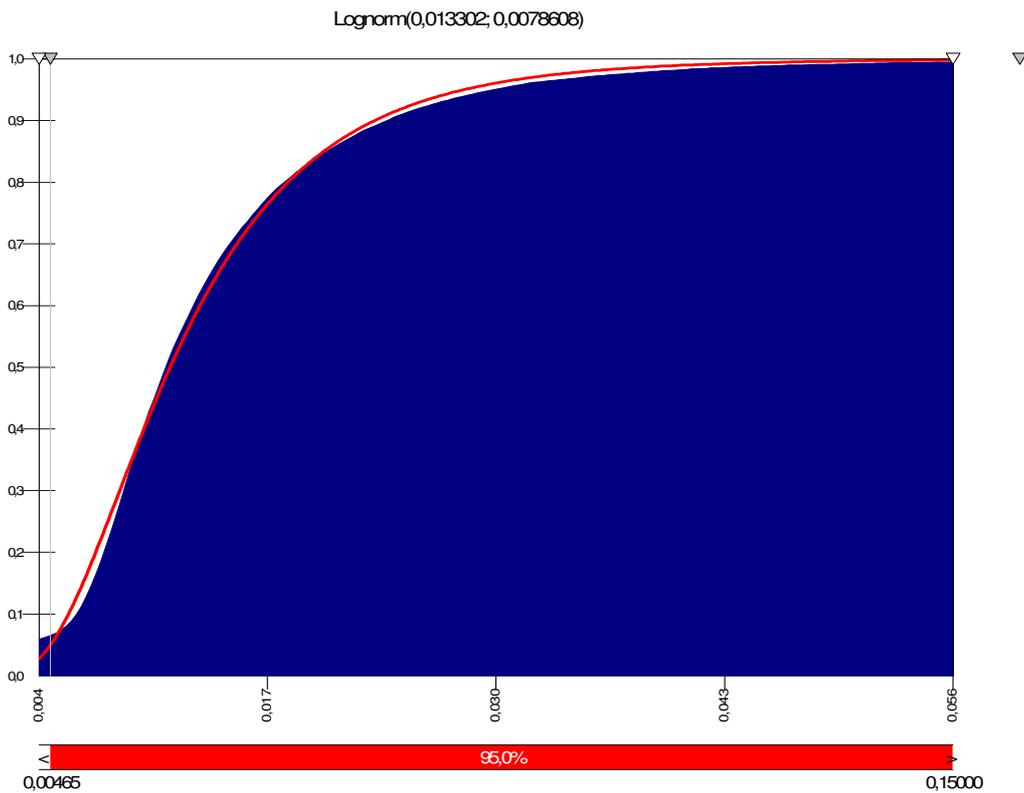


Diagramm 6.11: Verteilungsanpassung der Gesprächszeiten durch die Lognormalverteilung

Die Tatsache, dass sich die Exponentialverteilung als Verteilungsannahme erneut als suboptimal erweist, ist auch bei den übrigen 95 Stichprobenverteilungen nachzuweisen. Unten stehende Tabelle gibt dabei für die entsprechenden Wochentagskategorien, analog zur Tabelle aus der Interarrivalzeitenanalyse, die jeweils besseren Verteilungen an.

| Wochentag | Optimale Verteilung |
|----------------------|----------------------------|
| Montag | Gamma |
| Dienstag bis Freitag | Lognormalverteilung |
| Samstag | Gamma |
| Sonntag | Gamma |

Tabelle 6.9: Übersicht der optimalen Servicezeit-Verteilung

Es resultiert wiederum die Erkenntnis, dass die im Annahmensystem unterstellte Exponentialverteilung in der Praxis nie die optimale Verteilung darstellt und stattdessen die Gamma- und die Lognormal-Verteilung einen wesentlich besseren Fit ergeben.

6.3 Konsequenzen aus der Analyse der Interarrival- und Servicezeiten

Nach der ausführlichen Analyse der tatsächlichen Zwischenankunfts- sowie der Gesprächszeiten im Call Center ist festzuhalten, dass zum Teil wesentliche Prämissenverletzungen vorliegen. So existieren nicht nur zeitabhängige und damit dynamische Ankunftsdaten, sondern auch zeitvariable Gesprächszeiten. Weiterhin sind die jeweiligen Verteilungsannahmen völlig unrealistisch und liegen damit fernab von den tatsächlichen Gegebenheiten.

Als Konsequenz hieraus ergibt sich, dass das Erlang C-Modell in der Praxis nicht mehr haltbar ist und die Personaleinsatzplanung in Call Centern damit neu überdacht werden muss. Aus theoretischer Sicht bereiten die ermittelten Verteilungen gewisse Schwierigkeiten bei der exakten Herleitung eines realistischen Planungsmodells. Aus diesem Grund wird eine Simulationsstudie angelegt, in der die Prämissenverletzungen berücksichtigt werden können. Dies wird Gegenstand des folgenden Kapitels sein.

6.4 Simulation der Personaleinsatzplanung unter einem realistischen Annahmensystem

Aus den vorangegangenen Untersuchungen wurde ersichtlich, dass die Servicezeiten lediglich abschnittsweise, nämlich jeweils innerhalb von 60-Minuten-Intervallen, stationär sind. Die größte Problematik resultiert allerdings aus der Tatsache, dass die Verteilungsannahmen im Erlang C-Modell nur suboptimal sind und in Wirklichkeit andere Verteilungen vorherrschen. Daraus folgt allerdings auch, dass die günstigen Eigenschaften der Exponentialverteilung nicht mehr zur Berechnung der entsprechenden Wahrscheinlichkeitsverteilungen für die durchschnittlichen Wartezeiten herangezogen werden können.

Einen Ausweg hierfür bietet allerdings die Möglichkeit einer Simulation der Ablaufprozesse im Call Center. Damit können die tatsächlichen empirischen Verteilungen modelliert und damit eine realitätsnahe Planung des Personaleinsatzes erstellt werden.

6.4.1 Einstellungsparameter und wichtige Kenngrößen als Referenzmaße

Zunächst werden die wichtigsten Eckpunkte dargelegt, die die Grundlage der Simulation bilden.

Als Basis der Berechnung gilt ein Excel Add-In, das mit Hilfe von Visual Basic Programmen die wichtigsten Kenngrößen der Warteschlangentheorie berechnen kann. Dieses Ausgangsmodell wurde für den vorliegenden Zweck erweitert und modifiziert.¹⁸⁰ Zum einen können die tatsächlichen Verteilungen ihren Eingang im Modell finden, d. h. unter Maßgabe der ermittelten empirischen Verteilungen werden die Interarrival- und Gesprächszeiten entsprechend generiert. Da das Simulationsmodell in ihren Grundlagen andererseits auf stationären Annahmen

¹⁸⁰ Das Programm QTS, sowie die Simulationsergebnisse können auf der beigefügten DVD gestartet werden. Der Quellcode der eigenständig durchgeführten Modifikationen und Erweiterungen von QTS in Visual Basic befinden sich im Anhang A5.

basiert und die Call Center Kenngrößen zudem auf dieser Prämisse basierend simuliert werden, sind die Untersuchungseinheiten so klein zu wählen, dass in ihnen die Parameter tatsächlich auch stationär sind. Bei den vorliegenden Daten konnte diese Stationarität in den 60-Minuten-Intervallen nachgewiesen werden, so dass die bereits gebildeten Stundenintervalle hier wieder ihren Eingang finden. Der dynamischen Komponente, die die Ankunfts- und Servicezeiten aufweisen, wird dadurch Rechnung getragen, dass die entsprechenden Verteilungsparameter im Tagesverlauf nicht konstant sind, sondern im Zeitablauf variieren. Es geht also für jede Stunde der jeweils optimalste Fit mit seinen entsprechenden Verteilungsparametern in die Simulation ein.

Die Inputfaktoren für die Simulation eines einzigen 60-Minuten-Intervalls sind damit:

- Verteilung der Interarrivalzeiten und ihre Verteilungsparameter,
- Verteilung der Servicezeiten und ihre Verteilungsparameter,
- Anzahl der zur Verfügung stehenden c Agenten (mit $c=1, \dots, 50$).

Ein einziger Durchlauf simuliert unter den eingestellten Prämissen insgesamt 1000 Testsituationen und errechnet dabei unter anderem die *Agentenauslastung* („Server utilization ρ “) und die *mittlere Wartezeit der Kunden in der Warteschlange* („Mean waiting time in the queue“). Diese beiden Größen werden später in der Auswertung der Simulation die zentralen Bestimmungsgrößen sein.

Für ein Stundenintervall resultieren somit insgesamt jeweils 50 (da bis maximal $c=50$ Agenten simuliert wird) verschiedene Werte für die Agentenauslastung und die mittlere Wartezeit in der Schlange, so dass pro Wochentagkategorie 1200 Simulationsergebnisse auszuwerten sind. Insgesamt resultieren mit den vier zu unterscheidenden Wochentagkategorien („Montag“, „Dienstag bis Freitag“, „Samstag“ und „Sonntag“) 4800 Datensätze, die jeweils in Abhängigkeit der Verteilungen und verfügbaren Agenten, die Agentenauslastung sowie die mittlere Wartezeit der Kunden in der Warteschlange zurückgeben.¹⁸¹

¹⁸¹ Die Ergebnisse der Simulationsstudie können ebenfalls auf der beigefügten DVD eingesehen werden.

Grundsätzlich kann die optimale Anzahl an Operatoren je Stundenintervall anhand zweier Kriterien ermittelt werden:

Zum einen ist es möglich, anhand eines bestimmten vorgegebenen Servicelevels die Agentenzahl abzulesen. Im Falle eines Servicelevels von 80/20 müssten also 80% der Anrufer innerhalb von 20 Sekunden bearbeitet werden. Würde man allerdings in den Simulationsergebnissen bei der durchschnittlichen Wartezeit in der Schlange die geforderten 20 Sekunden ansetzen und bei diesem Wert die dafür benötigte Anzahl an Agenten ablesen, wäre der Servicelevel tatsächlich überschritten, da der Wert W_q in der Simulation lediglich die mittlere Wartezeit angibt. Somit stellt diese Kenngröße tatsächlich eine suboptimale Referenzgröße dar.

Die andere Möglichkeit zur Ermittlung der notwendigen Operatoren im Call Center kann durch die Agentenauslastung realisiert werden. In der Praxis wird stets versucht eine möglichst kleine Idle-Time der Operatoren zu realisieren, d. h. die Auslastung und damit Produktivität der Mitarbeiter soll möglichst hoch sein. Um die Agenten aber nicht zu sehr zu belasten und damit unmotivierten Mitarbeitern entgegenzuwirken, soll die Auslastung bei 80% oder knapp darunter liegen. Wird also die Agentenauslastung als Referenzgröße zur Bestimmung der optimalen Agentenzahl gewählt, so wird dem Kostenoptimierungsaspekt noch weiter Rechnung getragen.

Diese Größe wird bei der Auswertung der Simulationsergebnisse auch als Referenzgröße herangezogen.

6.4.2 Ergebnisse der Simulation und Bedeutung für die operative Personaleinsatzplanung

Im Falle der 4800 Datensätze würden sich gemäß der obigen Optimierungsgröße einer 80%-igen Agentenauslastung folgende notwendigen Agentenzahlen ergeben:

Um montags bei gammaverteilten Interarrival- und gammaverteilten Servicezeiten eine Agentenauslastung von 80% zu erzielen, müssen gemäß der

Simulationsergebnisse in den entsprechenden Stundenintervallen die untenstehenden Agentenzahlen im System verfügbar sein.

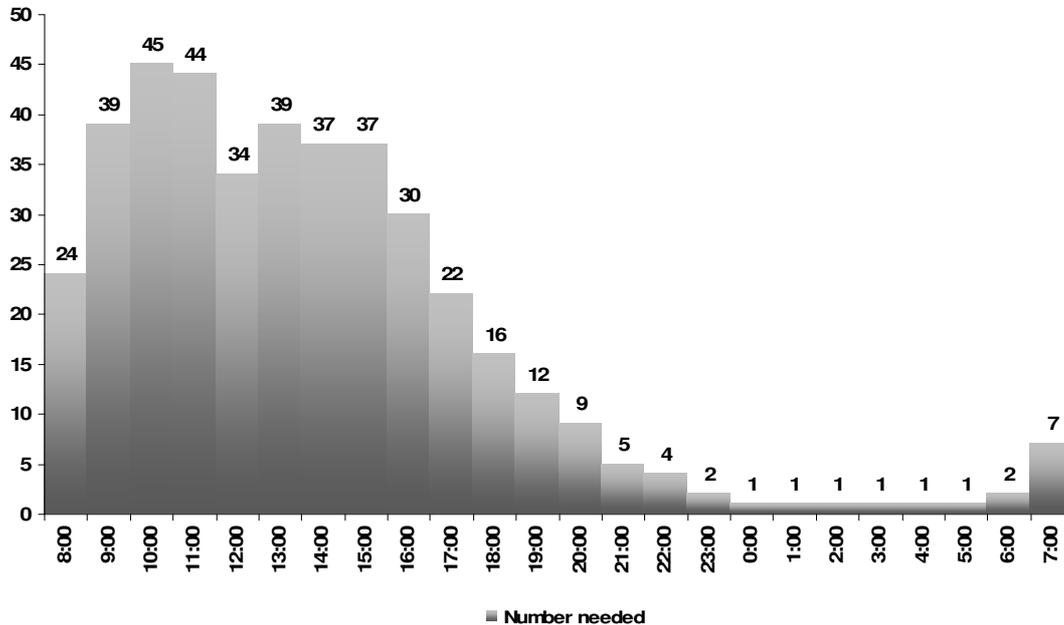


Abbildung 6.1: Simulationsergebnis montags

Obige Abbildung stellt zwar die Ergebnisse der Simulation dar und damit die für jede Stunde optimale Anzahl an Agenten, allerdings kann dieses Ergebnis nicht in dieser Form in die Praxis übernommen werden, denn es sind Schichtmodelle zu berücksichtigen.

Um mit Hilfe der Simulationsergebnisse ein effizientes Schichtmodell zu ermitteln, ist ein lineares ganzzahliges Optimierungsproblem zu lösen. Die Zielfunktion und die Nebenbedingungen lauten dabei folgendermaßen:

Es gilt die Anzahl der Agenten im Tagesverlauf zu minimieren, wobei unterstellt wird, dass jeder Mitarbeiter jeweils eine Arbeitszeit von sechs Stunden absolviert. Des Weiteren gehen die Ergebnisse der Simulation als Nebenbedingung ein, denn diese Werte dürfen nicht unterschritten werden. Die beiden letzten Bedingungen lauten, dass die Operatorenanzahl jeweils ganzzahlig und nicht-negativ sein darf.

Wird nun unter diesen Prämissen das Optimierungsproblem gelöst, so ergibt sich im Vergleich zur Simulationslösung, folgendes Schichtmodell für Montag:

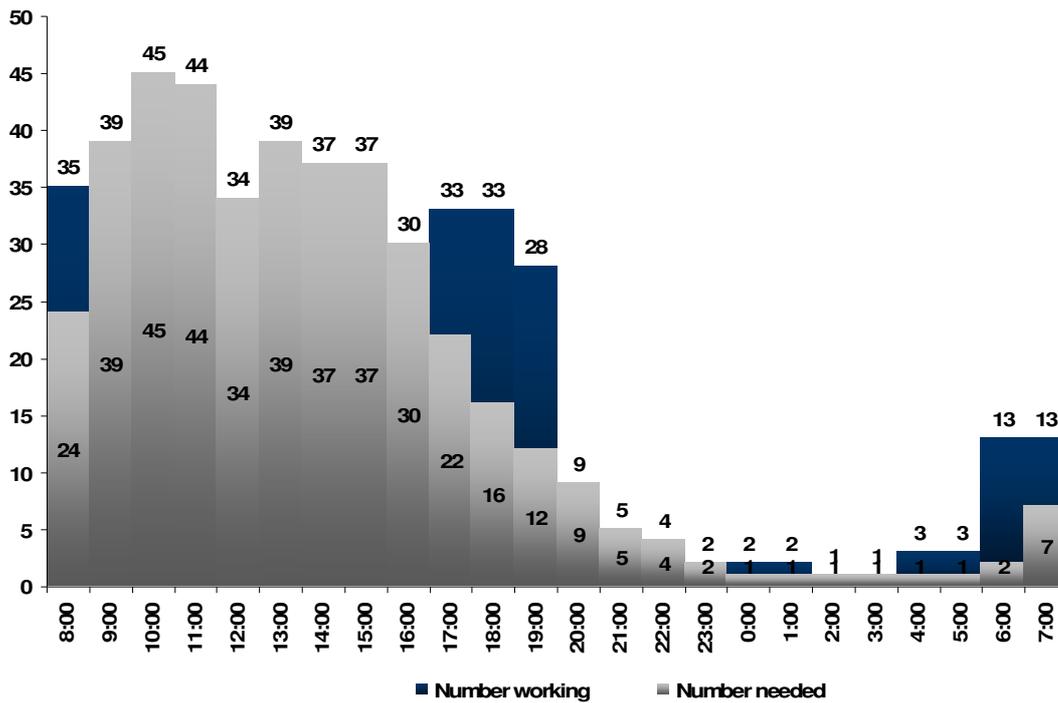


Abbildung 6.2: Schichtmodell montags

Die Darstellung zeigt das Schichtmodell anhand der blauen Balken. Der Vergleich mit der Ausgangslösung der Simulation zeigt, dass die Berücksichtigung von Schichtmodellen in diesem Fall den Personaleinsatz um 18,8% erhöht.

Ähnlich verhält es sich auch mit den übrigen Tagen.

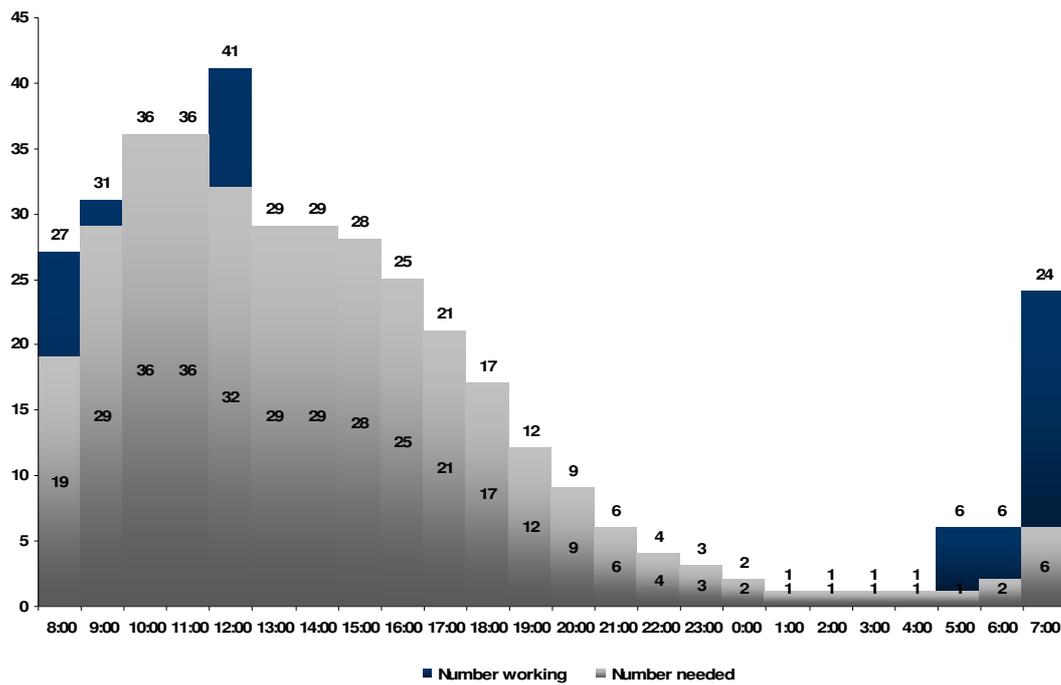


Abbildung 6.3: Schichtmodell Dienstag bis Freitag

Die Erhöhung des Personaleinsatzes an den Tagen Dienstag bis Freitag beträgt hier 13,14% und fällt damit weniger stark aus als montags.

An den Wochenendtagen Samstag und Sonntag resultieren die Einsatzpläne wie sie in Abbildung 6.4 und 6.5 dargestellt sind.

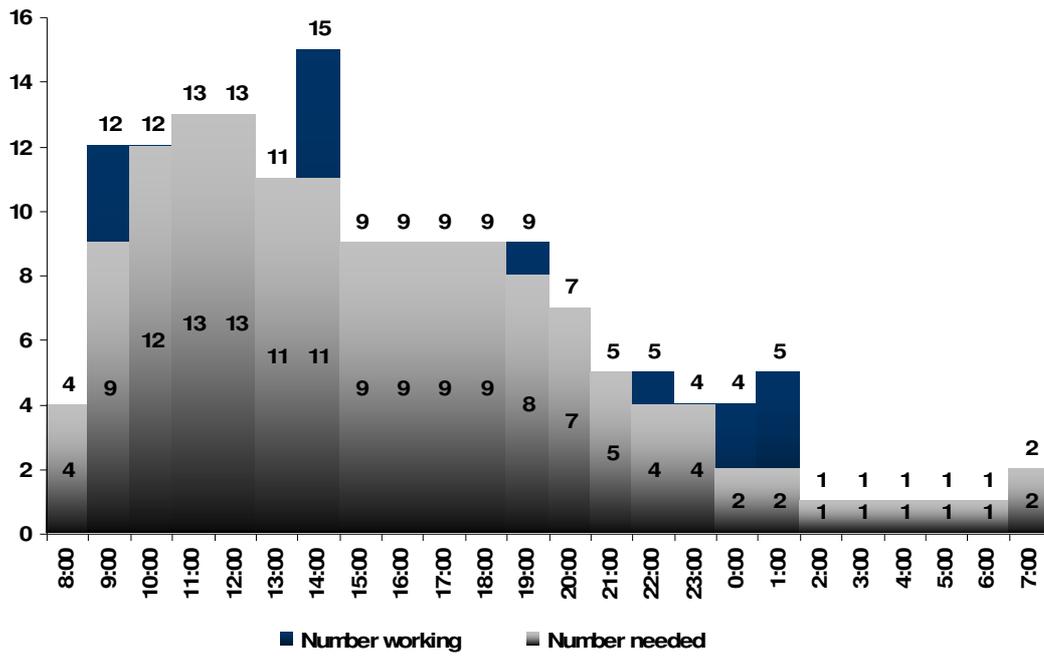


Abbildung 6.4: Schichtmodell samstags

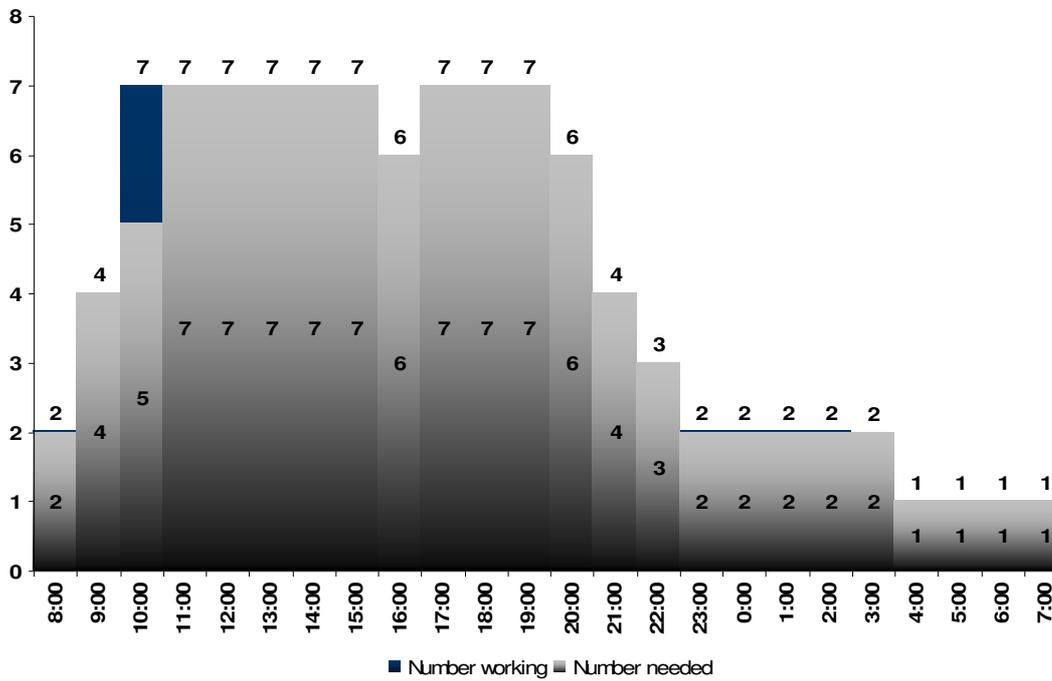


Abbildung 6.5: Schichtmodell sonntags

Auffallend ist, dass sich am Wochenende die Notwendigkeit der Berücksichtigung von Schichtmodellen weniger gravierend auswirken, als an Werktagen. So nimmt der Personaleinsatz an Samstagen um 8,64% und an Sonntagen sogar nur um 1,96% zu.

Die eben modellierten Personalschichten erlauben zwar nun eine realistische Einsatzplanung, allerdings sind hierin noch keine Pausen berücksichtigt. Deshalb gilt es in einem weiteren Schritt, die entsprechenden Schichtmodelle unter Einbeziehung einer 30-minütigen Pause eines jeden Agenten, drei Stunden nach Arbeitsantritt neu zu formulieren. Hierfür müssen die Stundenintervalle nun aber weiter in 30-Minuten-Intervalle aufgespalten werden. Alle anderen Nebenbedingungen von zuvor gehen auch hier in die Modellierung ein.

Für montags resultiert dann:

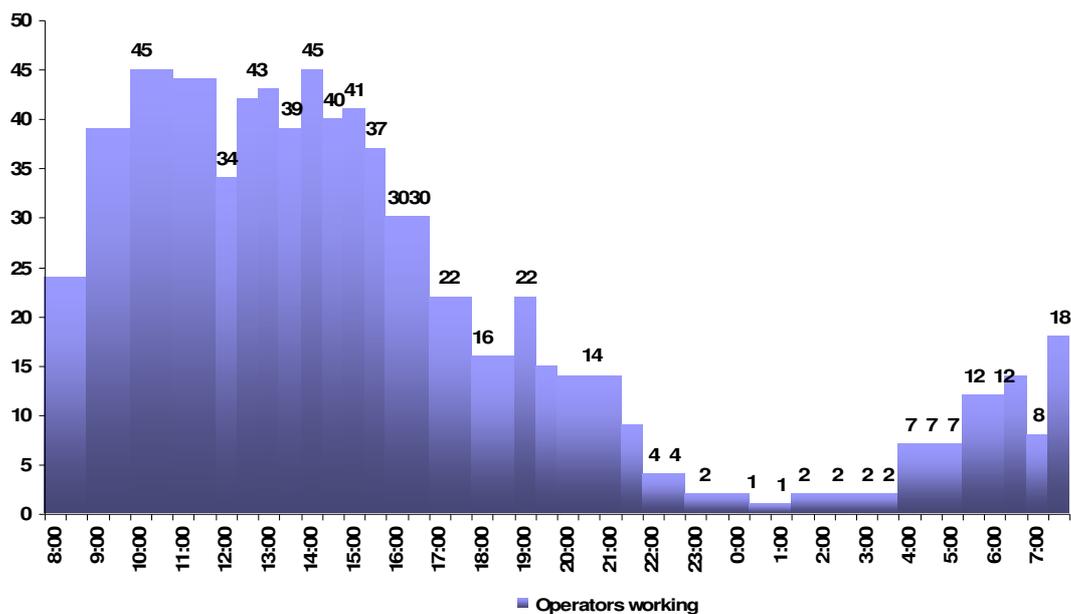


Abbildung 6.6: Schichtmodell mit Pausen (montags)

Das Einbeziehen von Pausenzeiten der Agenten verändert den Personaleinsatz für Montag nochmals geringfügig wie Abbildung 6.7 zeigt.

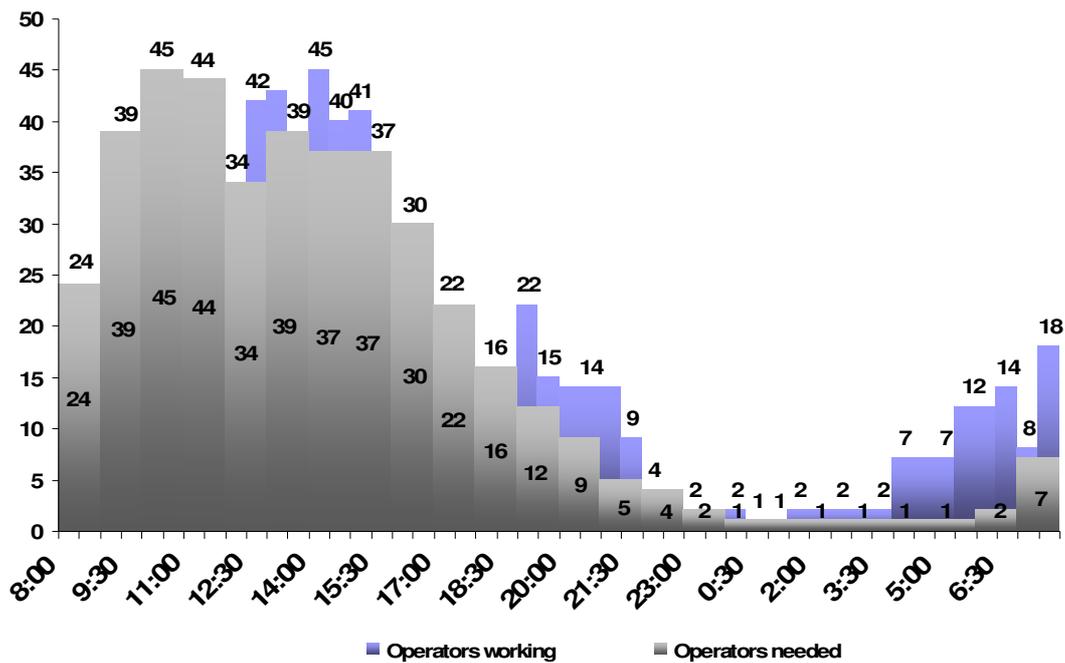


Abbildung 6.7: Vergleich des Schichtmodells mit Pausen mit dem Simulationsergebnis (montags)

Durch die konkrete Einplanung von Pausen verschieben sich die Einsätze der Agenten im Vergleich zum einfachen Schichtmodell ohne Pausen. Aber was viel entscheidender ist, ist der Vergleich des Schichtmodells mit Pausen zum Ausgangsmodell der Simulation. Die grau unterlegten Balken stellen dabei die Ergebnisse der Simulation dar, während die blau hinterlegten Balken die Agentenanzahl im Schichtmodell unter Berücksichtigung von Pausen angeben. Auch bei den übrigen drei berechneten Personaleinsatzmodellen zeigt sich, dass die Pausenzeiten ganz entscheidende Auswirkungen auf die Schichtmodelle haben.

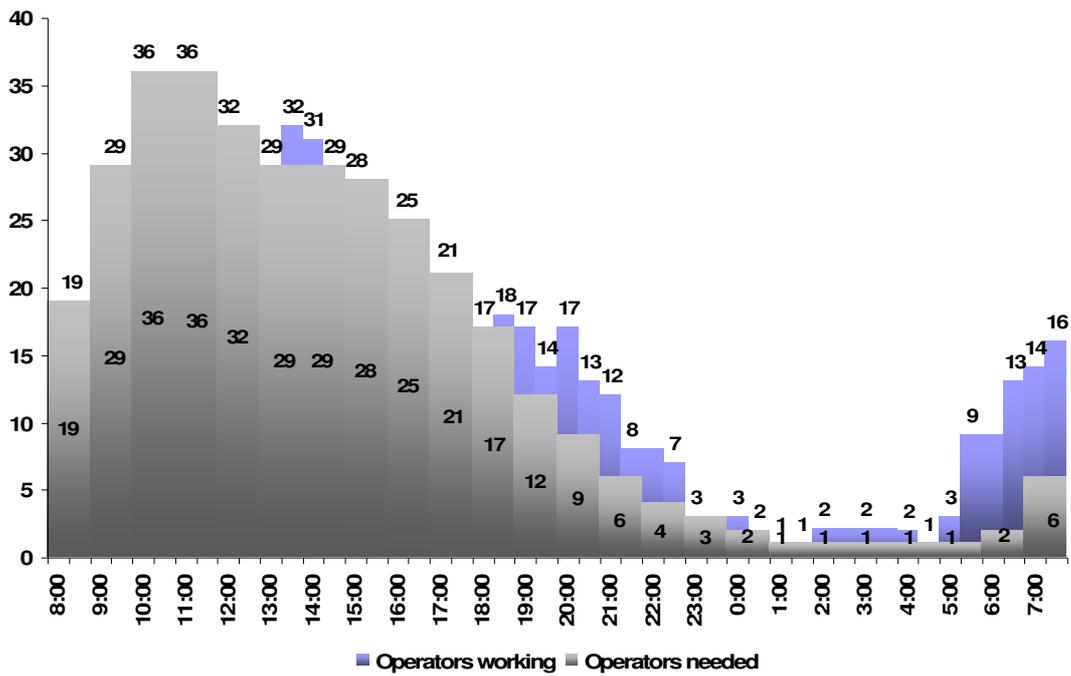


Abbildung 6.8: Vergleich des Schichtmodells mit Pausen mit dem Simulationsergebnis (Dienstag bis Freitag)

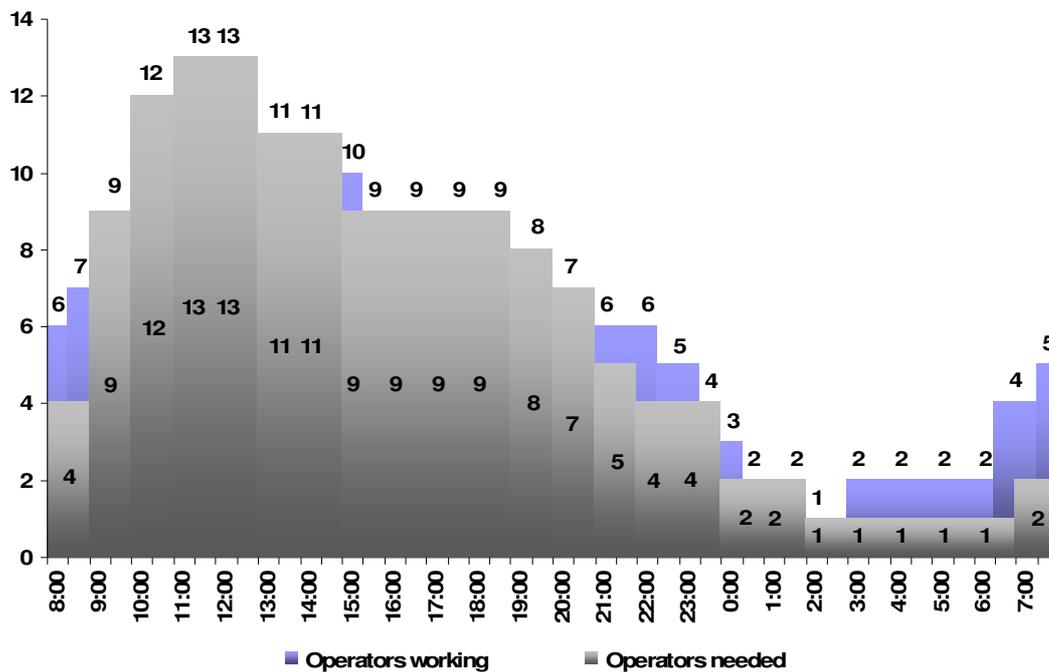


Abbildung 6.9: Vergleich des Schichtmodells mit Pausen mit dem Simulationsergebnis (Samstag)

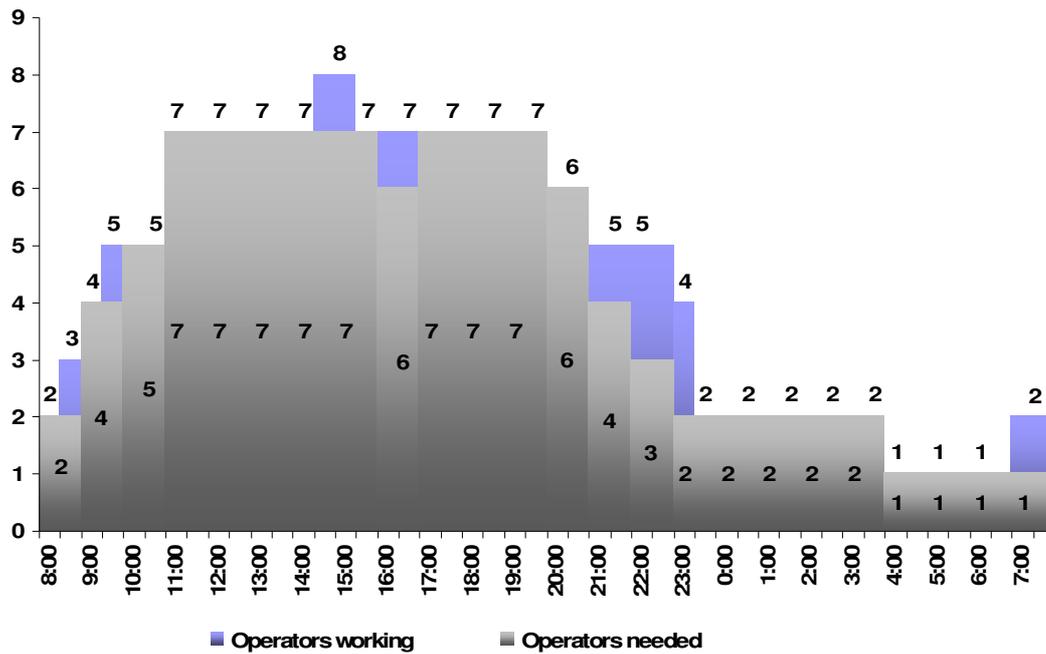


Abbildung 6.10: Vergleich des Schichtmodells mit Pausen mit dem Simulationsergebnis (Sonntag)

Auffällig ist, dass die Simulationsergebnisse am Wochenende stets weniger weit von dem tatsächlich anwendbaren Schichtmodell mit Pausen liegen. So steigt der notwendige Personaleinsatz an Samstagen lediglich um 9,46% und am Sonntag sogar nur um 8%. Ein Grund hierfür ist, dass am Wochenende die Callperformance insgesamt konformer ist und Peaks im Anrufaufkommen weniger stark ausgeprägt sind als während der Woche. Damit schwanken die erforderlichen Operatoren weniger stark im Tagesablauf und eine nachträgliche Berücksichtigung von Pausenzeiten wirkt sich damit auch schwächer auf den Personaleinsatz aus.

6.4.3 Vergleich des Schichtmodells aus der Simulationsstudie mit dem aus der traditionellen Personaleinsatzplanung

Viel interessanter und für die Beurteilung der Simulationsstudie aussagekräftiger ist allerdings der Vergleich des neu berechneten Personaleinsatzes unter realitätsnäheren Prämissen mit dem Personalaufkommen nach dem Erlang C-Modell. In den folgenden Diagrammen wird mit der Bezeichnung „Operators working“ die Einsatzzahlen nach dem Simulationsmodell und mit „Referenz IST“ die aktuell im Call Center verfügbaren Agenten definiert.

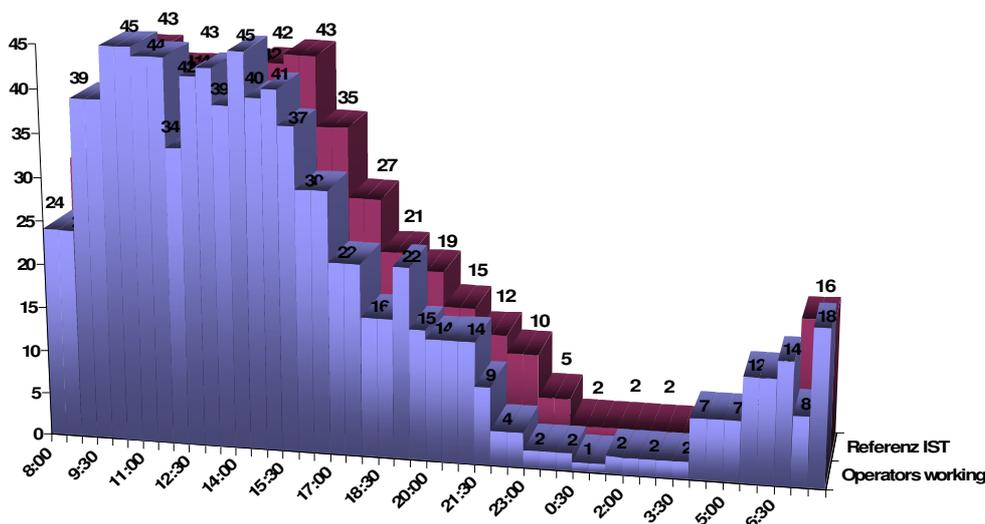


Abbildung 6.11: Vergleich des neu simulierten Modells mit dem traditionellen (Montag)

Wie bereits der Verlauf andeutet, kann für die Einsatzplanung an Montagen festgehalten werden, dass die Simulationsstudie auf Basis einer 80%-igen Personalauslastung das aktuelle Schichtmodell weniger personalintensiv modelliert wird. Insgesamt reduziert sich hier der Personalaufwand auf 96,58% vom ursprünglichen Personaleinsatz.

Noch gravierender wirken sich die Simulationsergebnisse auf die übrigen Tage aus, wie die Abbildungen 6.12 bis 6.14 zeigen.

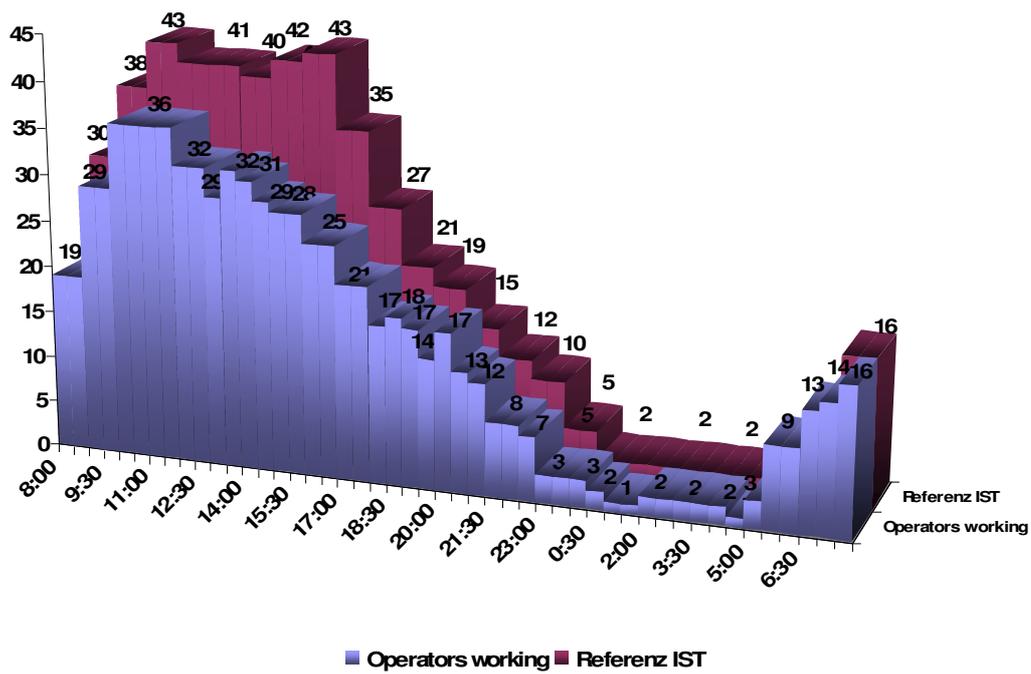


Abbildung 6.12: Vergleich des neu simulierten Modells mit dem traditionellen (Dienstag bis Freitag)

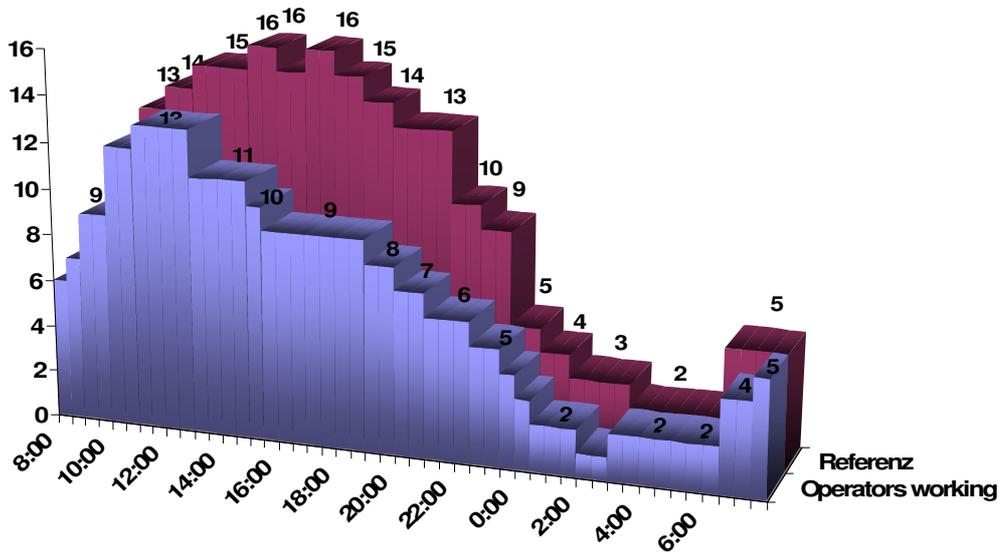


Abbildung 6.13: Vergleich des neu simulierten Modells mit dem traditionellen (Samstag)

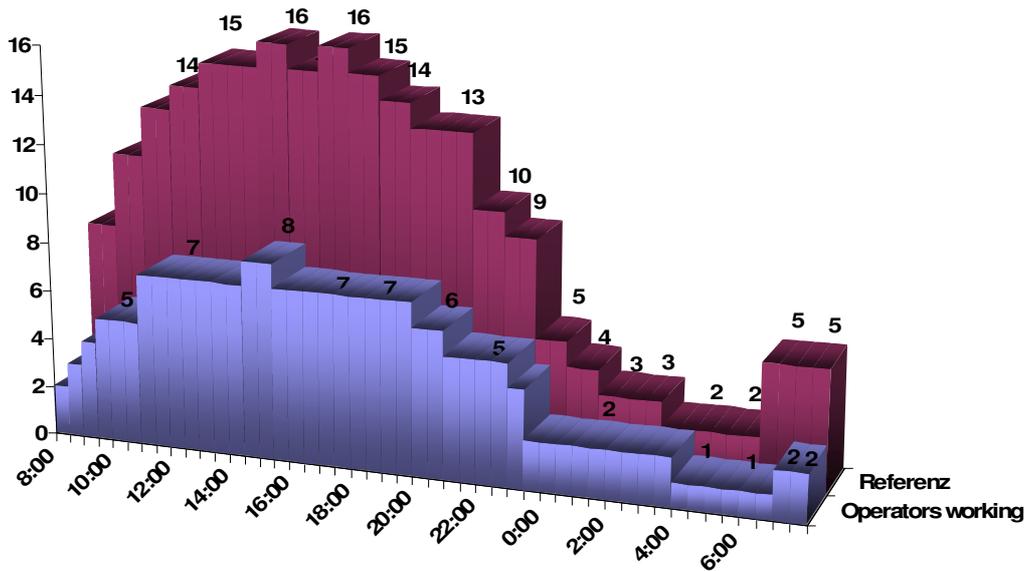


Abbildung 6.14: Vergleich des neu simulierten Modells mit dem traditionellen (Sonntag)

Während im Schichtmodell von „Dienstag bis Freitag“ die Personalintensität auf 79,68% der Ursprungsintensität reduziert werden kann, sinkt dieser Wert an Samstagen immerhin auf 71,05%. Äußerst auffällig ist aber das Einsparungspotenzial an Sonntagen. Hier kann der Agentenaufwand sogar um 52,63% gesenkt werden. Diese enorme Effizienzsteigerung wird ersichtlich, wenn die Idle-Times, also jene Zeiten, in denen die Operatoren auf Anrufe warten, näher betrachtet werden. Hierzu wurden die Idle-Times speziell für die Sonntage analysiert und im Tagesablauf die durchschnittliche prozentuale Auslastung berechnet.

Das untenstehende Diagramm zeigt das Ergebnis:

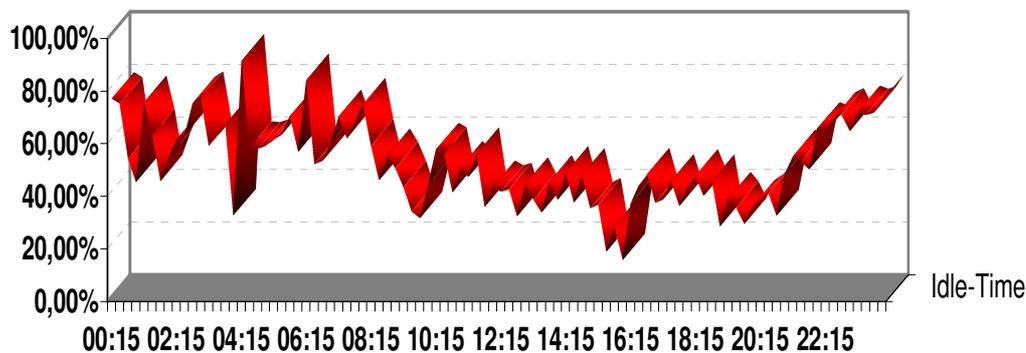


Diagramm 6.12: Durchschnittliche Idle-Time sonntags

Es wird deutlich, dass sich die Unterauslastung der Mitarbeiter den ganzen Tag hindurch auf einem relativ hohen Niveau bewegt. Im Mittel liegt der Wert bei 45,92%, das heißt die Agentenauslastung liegt an Sonntagen lediglich bei 54,08%, was somit auf eine schlechte Personaleinsatzplanung durch das Erlang C-Modell schließen lässt.

Dadurch, dass die Simulation die Optimierung bezüglich der Agentenauslastung errechnet, wird klar, weshalb die neu berechneten Einsatzpläne derart die Personalintensitäten reduzieren. Die extrem großen Idle-Times im Call Center werden durch die modifizierten Verteilungsannahmen deutlich reduziert und so der Personalaufwand gesenkt.

Das macht vor allem an Wochenenden Sinn. Montags hingegen ist das Einsparpotential gering, was darin begründet ist, dass die Mitarbeiter an diesen Tagen tatsächlich wenig unterausgelastet sind und damit das empirische Modell nahe bei der optimalen Einsatzplanung der Simulation liegt.

Abschließend sei der Vollständigkeit halber noch angemerkt, dass im Falle von Feiertagen analog die Simulationsergebnisse für Samstag und Sonntag angesetzt werden können. Analysen haben ergeben, dass das Callaufkommen an Feiertagen nicht signifikant verschieden ist mit dem an Wochenenden. Die entsprechenden Tests können dem Anhang A4.3 entnommen werden.

Kapitel 7: Zusammenfassung

Ziel dieser Arbeit war es, die herkömmliche Personaleinsatzplanung in Call Centern, speziell in Inbound Call Centern, zu untersuchen und nach Verbesserungsmöglichkeiten zu forschen.

Diese ergaben sich zum einen im Bereich der strategischen Personaleinsatzplanung, die sich mit der Prognose des Callaufkommens beschäftigt, um darauf aufbauend eine grobe Agentenplanung treffen zu können. Die Anwendung künstlicher neuronaler Netze zeigte, dass auf Basis historischer Call Center Daten eine sehr gute Prognose für das Callvolumen in der Zukunft berechnet werden kann. Voraussetzung hierfür ist zum einen eine fundierte Datenbasis, die über mehrere Perioden hinweg die entsprechenden Anrufzahlen enthält und zum anderen bedarf es einiger Kenntnisse über die Systematik der neuronalen Netzen, insbesondere der Multi-Layer Perceptrone, wie sie in Kapitel 3.4.3.3 dargestellt wurden.

Die Auswahl der wichtigsten Einflussparameter auf die Anrufeingänge im Call Center ist nicht unproblematisch, zumal diese einerseits als solche identifiziert werden und dann auch in entsprechender Datenform vorliegen müssen. Gerade der Einfluss latenter Variablen auf das Callverhalten ist in der Praxis nur selten messbar und erschwert somit eine optimale Vorbereitung für die Prognose. Auch die Modellierung der Netzwerktopologie an sich und die richtige Wahl der Einstellungsparameter, wie Lernrate oder Momentum-Term, sind nicht zu unterschätzen, zumal sie die Performance des Netzwerkes entscheidend beeinflussen können, wie in Kapitel 4.4 gezeigt wurde. Dennoch wiegen diese Probleme nicht so schwer, als dass sie den großen Vorteil einer sehr präzisen Prognosefähigkeit der Call Daten aufwiegen könnten.

Im ersten empirischen Teil der Arbeit wurde schon deutlich, wie leistungsfähig die Multi-Layer Perzeptrone sind und wie gut mit ihrer Hilfe die Callverläufe angepasst werden können (Kapitel 4.5).

Eine gute Prognose der Arbeitslast im Call Center ist ausschlaggebend für strategische Personalentscheidungen. Der Trend einer sukzessiven Zunahme der Arbeitslast würde zur Aufstockung des Agentenstammes oder zur konsequenten Weiterbildung der bestehenden Operatoren führen. Je früher diese Tendenz

eingesehen werden kann, umso besser kann sich das Call Center darauf einstellen und entsprechende Maßnahmen einleiten.

Während manche Unternehmen die künftigen Callvolumina nur auf Basis von Erfahrungswerten abschätzen, erlaubt der Einsatz künstlicher neuronaler Netze ausführlichere und detaillierte Prognosen, die flexibel einsetzbar sind.

Ein wesentlicher Punkt hierbei ist auch, dass im Zuge eines integrierten Data Warehouse der Arbeitsprozess von der Erfassung der Call Daten über die Telekommunikationsanlage bis zur Prognose der künftig zu erwartenden Arbeitslast sehr leicht zu implementieren ist. Das für die Prognose verwendete Software-Paket Clementine verfügt über eine Schnittstelle zu den herkömmlichen Datenbanken und kann auch entsprechend erweitert werden. Es könnte also eine Automatisierung dahin gehend erfolgen, dass die Daten der Telekommunikationsanlage sofort in die entsprechenden Trainings und Test Sets der in Clementine festgelegten Netze einfließen und damit eine stetige und vor allem aktuelle Datenbasis zur Prognose vorliegt. Damit gestaltet sich das Training stets auf einem höchst aktuellen Niveau und eventuelle Verschiebungen in den Gewichtungen einzelner Einflussfaktoren fließen sofort in die Vorhersagen mit ein. Somit ist auch eine sehr hohe Flexibilität in der Anpassung an externe Einflüsse auf das Callniveau gegeben.

Der zweite Aspekt im Zusammenhang mit der Personaleinsatzplanung ist die der operativen Planung. Hierbei basieren die herkömmlichen Planungsmodelle auf den theoretischen Grundlagen des Erlang C-Modells. Zwar können hiermit jene Kennzahlen berechnet werden, die in Abhängigkeit der verfügbaren Agentenzahl Aufschluss über das Serviceniveau des Call Centers geben und damit Basis für die Einsatzplanung sind, aber das Modell unterliegt den äußerst restriktiven Annahmen aus Kapitel 5.4.1. Wie in den Kapiteln 6.1.3 und 6.2.3 gezeigt werden konnte, ist vor allem die Verteilungsannahme der Exponentialverteilung weder für die Interarrival- noch für die Servicezeiten gegeben. Diese Prämissenverletzungen stellen die praktische Anwendungsfähigkeit des Erlang Modells in Frage, weshalb die Simulationsstudie in Kapitel 6.4 durchgeführt wurde. Der Vorteil hierbei lag darin, dass die tatsächlich in der Praxis vorliegenden Verteilungen mit den expliziten Verteilungsparametern miteinbezogen und zusätzlich dynamische Komponenten, wie

die zeitlich stark schwankenden Calleingänge oder die variierenden Gesprächszeiten, implementiert werden konnten. Die Prämissenverletzungen des Erlang C-Modells wurden dadurch abgefangen und eine realistische Call Center Situation konnte simuliert werden. Das Optimierungskriterium für die Berechnung der optimalen Agentenauswahl war die einer 80%-ige Agentenauslastung. Hiermit kann auch einer kosteneffizienten Planung Rechnung getragen werden, ohne das Servicelevel zu sehr zu gefährden. Als Ergebnis resultierte, dass die Simulation die herkömmliche Einsatzplanung dahingehend verbessert, als sie mit deutlich weniger Agenten plant. Die zunächst sehr hohen Idle-Zeiten der Agenten (vgl. Kapitel 6.4.3) werden durch das Kriterium einer 80%-igen Auslastung reduziert und die Schichtplanung effizienter gestaltet.

Es zeigt sich also, dass die Annahmen im Erlang C-Modell in der Realität zu restriktiv sind, als dass das Modell eine wirklich optimale Schichtplanung ermöglichen könnte. Für neu gegründete Call Center mag sie eine gute Hilfestellung sein, da diese Unternehmen nicht auf eigene Call Daten zurückgreifen können, um damit ein Simulation der Anrufprozesse durchführen zu können, allerdings empfiehlt es sich für etablierte Unternehmen, ihre operative Personalplanung auf die Resultate einer Simulation umzustellen. Die damit verbundenen Kosteneinsparungen im Bereich des Personalwesens sind evident und im Hinblick auf die Wettbewerbssituation am Markt nicht zu unterschätzen.

Anhang

A1 Überprüfung der Einflussparameter zur Callprognose

A1.1 Varianzanalyse für den Jahresvergleich des Callaufkommens

Zu unterscheiden sind die Jahre 2002, 2003 und 2004.

Oneway

Descriptives

Total Calltypes

| | N | Mean | Std. Deviation | Std. Error | 95% Confidence Interval for Mean | | Minimum | Maximum |
|-------|-----|----------|----------------|------------|----------------------------------|-------------|---------|---------|
| | | | | | Lower Bound | Upper Bound | | |
| 2002 | 60 | 12139,93 | 4162,675 | 537,399 | 11064,60 | 13215,27 | 4951 | 17967 |
| 2003 | 364 | 12748,37 | 4590,804 | 240,624 | 12275,18 | 13221,56 | 4642 | 20547 |
| 2004 | 244 | 14839,32 | 5565,685 | 356,306 | 14137,48 | 15541,17 | 4853 | 21140 |
| Total | 668 | 13457,48 | 5041,540 | 195,063 | 13074,47 | 13840,49 | 4642 | 21140 |

Test of Homogeneity of Variances

Total Calltypes

| Levene Statistic | df1 | df2 | Sig. |
|------------------|-----|-----|------|
| 15,711 | 2 | 665 | ,000 |

ANOVA

Total Calltypes

| | Sum of Squares | df | Mean Square | F | Sig. |
|----------------|----------------|-----|-------------|--------|------|
| Between Groups | 7,53E+08 | 2 | 376552740,5 | 15,457 | ,000 |
| Within Groups | 1,62E+10 | 665 | 24361078,09 | | |
| Total | 1,70E+10 | 667 | | | |

A1.2 Varianzanalyse für den Monatsvergleich

Es gelten folgende Codierungen:

1=Januar; 2=Februar; 3=März; 4=April; 5=Mai; 6=Juni; 7=Juli; 8=August;
9=September; 10=Oktober; 11=November; 12=Dezember.

Oneway

Descriptives

Total Calltypes

| | N | Mean | Std. Deviation | Std. Error | 95% Confidence Interval for Mean | | Minimum | Maximum |
|-------|-----|----------|----------------|------------|----------------------------------|-------------|---------|---------|
| | | | | | Lower Bound | Upper Bound | | |
| 1 | 31 | 12916,19 | 4293,252 | 771,091 | 11341,42 | 14490,97 | 5020 | 17837 |
| 2 | 28 | 12795,54 | 4335,176 | 819,271 | 11114,53 | 14476,54 | 4881 | 16835 |
| 3 | 30 | 11765,70 | 4260,586 | 777,873 | 10174,77 | 13356,63 | 4693 | 16280 |
| 4 | 30 | 11732,60 | 4448,319 | 812,148 | 10071,57 | 13393,63 | 4642 | 16624 |
| 5 | 31 | 11797,68 | 4391,523 | 788,741 | 10186,85 | 13408,50 | 4920 | 16518 |
| 6 | 30 | 12111,27 | 4663,452 | 851,426 | 10369,91 | 13852,63 | 4808 | 17222 |
| 7 | 31 | 12870,61 | 4152,375 | 745,789 | 11347,51 | 14393,72 | 4999 | 16712 |
| 8 | 31 | 12136,06 | 4396,765 | 789,682 | 10523,32 | 13748,81 | 4816 | 16689 |
| 9 | 30 | 14029,13 | 4659,399 | 850,686 | 12289,29 | 15768,98 | 5030 | 18446 |
| 10 | 31 | 13900,65 | 4857,347 | 872,405 | 12118,96 | 15682,33 | 4765 | 18982 |
| 11 | 30 | 13530,23 | 5149,226 | 940,116 | 11607,48 | 15452,99 | 5139 | 18490 |
| 12 | 31 | 13380,84 | 5300,017 | 951,911 | 11436,78 | 15324,90 | 5385 | 20547 |
| Total | 364 | 12748,37 | 4590,804 | 240,624 | 12275,18 | 13221,56 | 4642 | 20547 |

Test of Homogeneity of Variances

Total Calltypes

| Levene Statistic | df1 | df2 | Sig. |
|------------------|-----|-----|------|
| 1,421 | 11 | 352 | ,161 |

ANOVA

Total Calltypes

| | Sum of Squares | df | Mean Square | F | Sig. |
|----------------|----------------|-----|-------------|-------|------|
| Between Groups | 2,34E+08 | 11 | 21295421,94 | 1,011 | ,436 |
| Within Groups | 7,42E+09 | 352 | 21068606,82 | | |
| Total | 7,65E+09 | 363 | | | |

A1.3 Paarvergleich der Monate August und September

T-Test

Group Statistics

| | monat | N | Mean | Std. Deviation | Std. Error Mean |
|-----------------|-------|----|----------|----------------|-----------------|
| Total Calltypes | 8 | 31 | 12136,06 | 4396,765 | 789,682 |
| | 9 | 30 | 14029,13 | 4659,399 | 850,686 |

Independent Samples Test

| | | Levene's Test for Equality of Variances | | t-test for Equality of Means | | | | | | |
|-----------------|-----------------------------|---|------|------------------------------|--------|-----------------|-----------------|-----------------------|---|---------|
| | | F | Sig. | t | df | Sig. (2-tailed) | Mean Difference | Std. Error Difference | 95% Confidence Interval of the Difference | |
| | | | | | | | | | Lower | Upper |
| Total Calltypes | Equal variances assumed | ,000 | ,988 | -1,633 | 59 | ,108 | -1893,069 | 1159,597 | -4213,416 | 427,279 |
| | Equal variances not assumed | | | -1,631 | 58,513 | ,108 | -1893,069 | 1160,717 | -4216,064 | 429,926 |

A1.4 Paarvergleich der Monate August und Oktober

T-Test

Group Statistics

| | monat | N | Mean | Std. Deviation | Std. Error Mean |
|-----------------|-------|----|----------|----------------|-----------------|
| Total Calltypes | 8 | 31 | 12136,06 | 4396,765 | 789,682 |
| | 10 | 31 | 13900,65 | 4857,347 | 872,405 |

Independent Samples Test

| | | Levene's Test for Equality of Variances | | t-test for Equality of Means | | | | | | |
|-----------------|-----------------------------|---|------|------------------------------|--------|-----------------|-----------------|-----------------------|---|---------|
| | | F | Sig. | t | df | Sig. (2-tailed) | Mean Difference | Std. Error Difference | 95% Confidence Interval of the Difference | |
| | | | | | | | | | Lower | Upper |
| Total Calltypes | Equal variances assumed | ,320 | ,574 | -1,500 | 60 | ,139 | -1764,581 | 1176,728 | -4118,388 | 589,226 |
| | Equal variances not assumed | | | -1,500 | 59,414 | ,139 | -1764,581 | 1176,728 | -4118,865 | 589,704 |

A1.5 Varianzanalyse für den Tagesvergleich

Anmerkung: Die Datenbasis für diese Untersuchung ist geringfügig verändert, denn die vorliegenden Callwerte liegen bezogen auf 15 Minuten-Intervalle vor, d.h. im Datensatz ist die Anzahl der Anrufe je 15 Minuteneinheit angegeben. Aus diesem Grund dürfen die unten stehenden Mittelwerte nicht verwundern, denn, um wieder auf den Tagesdurchschnitt zu gelangen, müssen die Werte in der Tabelle mit 96 (da 24 Stunden à 4x15 Minuten-Intervalle pro Stunde = 96) multipliziert werden.

Oneway

Descriptives

Calls

| | N | Mean | Std. Deviation | Std. Error | 95% Confidence Interval for Mean | | Minimum | Maximum |
|-------|-------|--------|----------------|------------|----------------------------------|-------------|---------|---------|
| | | | | | Lower Bound | Upper Bound | | |
| 1 | 4092 | 166,94 | 148,615 | 2,323 | 162,38 | 171,49 | 0 | 533 |
| 2 | 3366 | 158,19 | 139,393 | 2,403 | 153,48 | 162,90 | 0 | 498 |
| 3 | 3551 | 150,52 | 132,145 | 2,218 | 146,18 | 154,87 | 0 | 478 |
| 4 | 3738 | 152,79 | 133,266 | 2,180 | 148,51 | 157,06 | 0 | 465 |
| 5 | 3726 | 143,40 | 124,406 | 2,038 | 139,41 | 147,40 | 0 | 463 |
| 6 | 4117 | 79,30 | 56,178 | ,876 | 77,59 | 81,02 | 1 | 363 |
| 7 | 3840 | 63,51 | 60,424 | ,975 | 61,60 | 65,42 | 0 | 463 |
| Total | 26430 | 129,62 | 124,351 | ,765 | 128,12 | 131,12 | 0 | 533 |

Test of Homogeneity of Variances

Calls

| Levene Statistic | df1 | df2 | Sig. |
|------------------|-----|-------|------|
| 2097,325 | 6 | 26423 | ,000 |

ANOVA

Calls

| | Sum of Squares | df | Mean Square | F | Sig. |
|----------------|----------------|-------|-------------|---------|------|
| Between Groups | 39918262 | 6 | 6653043,647 | 476,720 | ,000 |
| Within Groups | 3,69E+08 | 26423 | 13955,867 | | |
| Total | 4,09E+08 | 26429 | | | |

A1.6 Paarweiser Vergleich der Tagesperformances

Es gelten folgende Codierungen:

1=Montag; 2=Dienstag; 3=Mittwoch; 4=Donnerstag; 5=Freitag; 6=Samstag;
7=Sonntag.

T-Test

Group Statistics

| | Wochentag | N | Mean | Std. Deviation | Std. Error Mean |
|-------|-----------|------|--------|----------------|-----------------|
| Calls | 1 | 4187 | 164,36 | 147,984 | 2,287 |
| | 2 | 3652 | 153,01 | 136,113 | 2,252 |

Independent Samples Test

| | | Levene's Test for Equality of Variances | | t-test for Equality of Means | | | | | | |
|-------|-----------------------------|---|------|------------------------------|----------|-----------------|-----------------|-----------------------|---|--------|
| | | F | Sig. | t | df | Sig. (2-tailed) | Mean Difference | Std. Error Difference | 95% Confidence Interval of the Difference | |
| | | | | | | | | | Lower | Upper |
| Calls | Equal variances assumed | 71,116 | ,000 | 3,516 | 7837 | ,000 | 11,351 | 3,228 | 5,023 | 17,680 |
| | Equal variances not assumed | | | 3,536 | 7814,940 | ,000 | 11,351 | 3,210 | 5,059 | 17,644 |

T-Test

Group Statistics

| | Wochentag | N | Mean | Std. Deviation | Std. Error Mean |
|-------|-----------|------|--------|----------------|-----------------|
| Calls | 3 | 3647 | 148,23 | 131,281 | 2,174 |
| | 2 | 3652 | 153,01 | 136,113 | 2,252 |

Independent Samples Test

| | | Levene's Test for Equality of Variances | | t-test for Equality of Means | | | | | | |
|-------|-----------------------------|---|------|------------------------------|----------|-----------------|-----------------|-----------------------|---|-------|
| | | F | Sig. | t | df | Sig. (2-tailed) | Mean Difference | Std. Error Difference | 95% Confidence Interval of the Difference | |
| | | | | | | | | | Lower | Upper |
| Calls | Equal variances assumed | 9,327 | ,002 | -1,525 | 7297 | ,127 | -4,773 | 3,130 | -10,910 | 1,363 |
| | Equal variances not assumed | | | -1,525 | 7288,193 | ,127 | -4,773 | 3,130 | -10,910 | 1,363 |

T-Test

Group Statistics

| | Wochentag | N | Mean | Std. Deviation | Std. Error Mean |
|-------|-----------|------|--------|----------------|-----------------|
| Calls | 3 | 3647 | 148,23 | 131,281 | 2,174 |
| | 4 | 4025 | 146,35 | 130,907 | 2,063 |

Independent Samples Test

| | | Levene's Test for Equality of Variances | | t-test for Equality of Means | | | | | | |
|-------|-----------------------------|---|------|------------------------------|----------|-----------------|-----------------|-----------------------|---|-------|
| | | F | Sig. | t | df | Sig. (2-tailed) | Mean Difference | Std. Error Difference | 95% Confidence Interval of the Difference | |
| | | | | | | | | Lower | | Upper |
| Calls | Equal variances assumed | ,268 | ,605 | ,629 | 7670 | ,529 | 1,885 | 2,997 | -3,990 | 7,759 |
| | Equal variances not assumed | | | ,629 | 7591,754 | ,530 | 1,885 | 2,997 | -3,991 | 7,760 |

T-Test

Group Statistics

| | Wochentag | N | Mean | Std. Deviation | Std. Error Mean |
|-------|-----------|------|--------|----------------|-----------------|
| Calls | 5 | 3822 | 141,33 | 123,649 | 2,000 |
| | 4 | 4025 | 146,35 | 130,907 | 2,063 |

Independent Samples Test

| | | Levene's Test for Equality of Variances | | t-test for Equality of Means | | | | | | |
|-------|-----------------------------|---|------|------------------------------|----------|-----------------|-----------------|-----------------------|---|-------|
| | | F | Sig. | t | df | Sig. (2-tailed) | Mean Difference | Std. Error Difference | 95% Confidence Interval of the Difference | |
| | | | | | | | | Lower | | Upper |
| Calls | Equal variances assumed | 36,973 | ,000 | -1,744 | 7845 | ,081 | -5,019 | 2,878 | -10,661 | ,622 |
| | Equal variances not assumed | | | -1,747 | 7844,781 | ,081 | -5,019 | 2,874 | -10,652 | ,614 |

T-Test

Group Statistics

| | Wochentag | N | Mean | Std. Deviation | Std. Error Mean |
|-------|-----------|------|--------|----------------|-----------------|
| Calls | 5 | 3822 | 141,33 | 123,649 | 2,000 |
| | 6 | 4117 | 79,30 | 56,178 | ,876 |

Independent Samples Test

| | | Levene's Test for Equality of Variances | | t-test for Equality of Means | | | | | | |
|-------|-----------------------------|---|------|------------------------------|----------|-----------------|-----------------|-----------------------|---|--------|
| | | F | Sig. | t | df | Sig. (2-tailed) | Mean Difference | Std. Error Difference | 95% Confidence Interval of the Difference | |
| | | | | | | | | Lower | | Upper |
| Calls | Equal variances assumed | 3630,118 | ,000 | 29,113 | 7937 | ,000 | 62,027 | 2,131 | 57,851 | 66,204 |
| | Equal variances not assumed | | | 28,410 | 5246,865 | ,000 | 62,027 | 2,183 | 57,747 | 66,307 |

T-Test

Group Statistics

| | Wochentag | N | Mean | Std. Deviation | Std. Error Mean |
|-------|-----------|------|-------|----------------|-----------------|
| Calls | 7 | 3840 | 63,51 | 60,424 | ,975 |
| | 6 | 4117 | 79,30 | 56,178 | ,876 |

Independent Samples Test

| | | Levene's Test for Equality of Variances | | t-test for Equality of Means | | | | | | |
|-------|-----------------------------|---|------|------------------------------|----------|-----------------|-----------------|-----------------------|---|---------|
| | | F | Sig. | t | df | Sig. (2-tailed) | Mean Difference | Std. Error Difference | 95% Confidence Interval of the Difference | |
| | | | | | | | | | Lower | Upper |
| Calls | Equal variances assumed | 134,050 | ,000 | -12,081 | 7955 | ,000 | -15,792 | 1,307 | -18,354 | -13,230 |
| | Equal variances not assumed | | | -12,051 | 7797,365 | ,000 | -15,792 | 1,310 | -18,361 | -13,223 |

T-Test

Group Statistics

| | Wochentag | N | Mean | Std. Deviation | Std. Error Mean |
|-------|-----------|------|--------|----------------|-----------------|
| Calls | 1 | 4187 | 164,36 | 147,984 | 2,287 |
| | 7 | 3840 | 63,51 | 60,424 | ,975 |

Independent Samples Test

| | | Levene's Test for Equality of Variances | | t-test for Equality of Means | | | | | | |
|-------|-----------------------------|---|------|------------------------------|----------|-----------------|-----------------|-----------------------|---|---------|
| | | F | Sig. | t | df | Sig. (2-tailed) | Mean Difference | Std. Error Difference | 95% Confidence Interval of the Difference | |
| | | | | | | | | | Lower | Upper |
| Calls | Equal variances assumed | 5854,995 | ,000 | 39,330 | 8025 | ,000 | 100,848 | 2,564 | 95,821 | 105,874 |
| | Equal variances not assumed | | | 40,563 | 5642,914 | ,000 | 100,848 | 2,486 | 95,974 | 105,722 |

A1.7 Vergleich Wochenende/Feiertag und Werktag

T-Test

Group Statistics

| | FEgew06 | N | Mean | Std. Deviation | Std. Error Mean |
|-------|---------|-------|--------|----------------|-----------------|
| Calls | 0 | 18473 | 154,58 | 136,258 | 1,003 |
| | 6 | 8817 | 71,64 | 57,942 | ,617 |

Independent Samples Test

| | | Levene's Test for Equality of Variances | | t-test for Equality of Means | | | | | | |
|-------|-----------------------------|---|------|------------------------------|-----------|-----------------|-----------------|-----------------------|---|--------|
| | | F | Sig. | t | df | Sig. (2-tailed) | Mean Difference | Std. Error Difference | 95% Confidence Interval of the Difference | |
| | | | | | | | | | Lower | Upper |
| Calls | Equal variances assumed | 12809,829 | ,000 | 54,840 | 27288 | ,000 | 82,942 | 1,512 | 79,978 | 85,907 |
| | Equal variances not assumed | | | 70,457 | 26999,850 | ,000 | 82,942 | 1,177 | 80,635 | 85,250 |

A1.8 Analyse des Interaktionseffekts (Intercept) von Feiertag und Wochentag

Varianzanalyse:

Oneway

Descriptives

Calls

| | N | Mean | Std. Deviation | Std. Error | 95% Confidence Interval for Mean | | Minimum | Maximum |
|-------|-------|--------|----------------|------------|----------------------------------|-------------|---------|---------|
| | | | | | Lower Bound | Upper Bound | | |
| ,00 | 18473 | 154,58 | 136,258 | 1,003 | 152,61 | 156,54 | 0 | 533 |
| 1,00 | 95 | 53,22 | 34,841 | 3,575 | 46,12 | 60,32 | 1 | 108 |
| 2,00 | 286 | 92,00 | 62,208 | 3,678 | 84,76 | 99,24 | 3 | 250 |
| 3,00 | 96 | 63,56 | 38,308 | 3,910 | 55,80 | 71,32 | 6 | 140 |
| 4,00 | 287 | 62,51 | 38,180 | 2,254 | 58,07 | 66,94 | 4 | 129 |
| 5,00 | 96 | 60,81 | 36,987 | 3,775 | 53,32 | 68,31 | 8 | 124 |
| 6,00 | 4117 | 79,30 | 56,178 | ,876 | 77,59 | 81,02 | 1 | 363 |
| 7,00 | 3840 | 63,51 | 60,424 | ,975 | 61,60 | 65,42 | 0 | 463 |
| Total | 27290 | 127,78 | 123,112 | ,745 | 126,32 | 129,24 | 0 | 533 |

Test of Homogeneity of Variances

Calls

| Levene Statistic | df1 | df2 | Sig. |
|------------------|-----|-------|------|
| 1880,827 | 7 | 27282 | ,000 |

ANOVA

Calls

| | Sum of Squares | df | Mean Square | F | Sig. |
|----------------|----------------|-------|-------------|---------|------|
| Between Groups | 41746726 | 7 | 5963817,980 | 437,539 | ,000 |
| Within Groups | 3,72E+08 | 27282 | 13630,375 | | |
| Total | 4,14E+08 | 27289 | | | |

A1.9 Sukzessiver Paarvergleich zur Identifikation jener Interaktionseffekte, die zur Ablehnung der Varianzanalyse führten

T-Test

Group Statistics

| | interceptFEWT | N | Mean | Std. Deviation | Std. Error Mean |
|-------|---------------|-----|-------|----------------|-----------------|
| Calls | 1,00 | 95 | 53,22 | 34,841 | 3,575 |
| | 2,00 | 286 | 92,00 | 62,208 | 3,678 |

Independent Samples Test

| | | Levene's Test for Equality of Variances | | t-test for Equality of Means | | | | | | |
|-------|-----------------------------|---|------|------------------------------|---------|-----------------|-----------------|-----------------------|---|---------|
| | | F | Sig. | t | df | Sig. (2-tailed) | Mean Difference | Std. Error Difference | 95% Confidence Interval of the Difference | |
| | | | | | | | | Lower | Upper | |
| Calls | Equal variances assumed | 23,483 | ,000 | -5,779 | 379 | ,000 | -38,779 | 6,710 | -51,973 | -25,585 |
| | Equal variances not assumed | | | -7,560 | 290,899 | ,000 | -38,779 | 5,129 | -48,874 | -28,684 |

T-Test

Group Statistics

| | interceptFEWT | N | Mean | Std. Deviation | Std. Error Mean |
|-------|---------------|-----|-------|----------------|-----------------|
| Calls | 3,00 | 96 | 63,56 | 38,308 | 3,910 |
| | 2,00 | 286 | 92,00 | 62,208 | 3,678 |

Independent Samples Test

| | | Levene's Test for Equality of Variances | | t-test for Equality of Means | | | | | | |
|-------|-----------------------------|---|------|------------------------------|---------|-----------------|-----------------|-----------------------|---|---------|
| | | F | Sig. | t | df | Sig. (2-tailed) | Mean Difference | Std. Error Difference | 95% Confidence Interval of the Difference | |
| | | | | | | | | Lower | Upper | |
| Calls | Equal variances assumed | 17,239 | ,000 | -4,217 | 380 | ,000 | -28,438 | 6,744 | -41,698 | -15,177 |
| | Equal variances not assumed | | | -5,297 | 267,698 | ,000 | -28,438 | 5,368 | -39,007 | -17,868 |

T-Test

Group Statistics

| | interceptFEWT | N | Mean | Std. Deviation | Std. Error Mean |
|-------|---------------|-----|-------|----------------|-----------------|
| Calls | 3,00 | 96 | 63,56 | 38,308 | 3,910 |
| | 4,00 | 287 | 62,51 | 38,180 | 2,254 |

Independent Samples Test

| | | Levene's Test for Equality of Variances | | t-test for Equality of Means | | | | | | |
|-------|-----------------------------|---|------|------------------------------|---------|-----------------|-----------------|-----------------------|---|-------|
| | | F | Sig. | t | df | Sig. (2-tailed) | Mean Difference | Std. Error Difference | 95% Confidence Interval of the Difference | |
| | | | | | | | | | Lower | Upper |
| Calls | Equal variances assumed | ,025 | ,875 | ,235 | 381 | ,815 | 1,057 | 4,505 | -7,801 | 9,916 |
| | Equal variances not assumed | | | ,234 | 162,654 | ,815 | 1,057 | 4,513 | -7,854 | 9,969 |

T-Test

Group Statistics

| | interceptFEWT | N | Mean | Std. Deviation | Std. Error Mean |
|-------|---------------|-----|-------|----------------|-----------------|
| Calls | 5,00 | 96 | 60,81 | 36,987 | 3,775 |
| | 4,00 | 287 | 62,51 | 38,180 | 2,254 |

Independent Samples Test

| | | Levene's Test for Equality of Variances | | t-test for Equality of Means | | | | | | |
|-------|-----------------------------|---|------|------------------------------|---------|-----------------|-----------------|-----------------------|---|-------|
| | | F | Sig. | t | df | Sig. (2-tailed) | Mean Difference | Std. Error Difference | 95% Confidence Interval of the Difference | |
| | | | | | | | | | Lower | Upper |
| Calls | Equal variances assumed | ,299 | ,585 | -,379 | 381 | ,705 | -1,693 | 4,467 | -10,476 | 7,090 |
| | Equal variances not assumed | | | -,385 | 167,714 | ,701 | -1,693 | 4,397 | -10,372 | 6,987 |

T-Test

Group Statistics

| | interceptFEWT | N | Mean | Std. Deviation | Std. Error Mean |
|-------|---------------|------|-------|----------------|-----------------|
| Calls | 5,00 | 96 | 60,81 | 36,987 | 3,775 |
| | 6,00 | 4117 | 79,30 | 56,178 | ,876 |

Independent Samples Test

| | | Levene's Test for Equality of Variances | | t-test for Equality of Means | | | | | | |
|-------|-----------------------------|---|------|------------------------------|---------|-----------------|-----------------|-----------------------|---|---------|
| | | F | Sig. | t | df | Sig. (2-tailed) | Mean Difference | Std. Error Difference | 95% Confidence Interval of the Difference | |
| | | | | | | | | | Lower | Upper |
| Calls | Equal variances assumed | 27,645 | ,000 | -3,208 | 4211 | ,001 | -18,490 | 5,763 | -29,788 | -7,192 |
| | Equal variances not assumed | | | -4,771 | 105,488 | ,000 | -18,490 | 3,875 | -26,173 | -10,807 |

A1.10 Mittelwertvergleich unter Ausschluss von „normalen“ Werktagen (kein Feiertag)

Oneway

Descriptives

Calls

| | N | Mean | Std. Deviation | Std. Error | 95% Confidence Interval for Mean | | Minimum | Maximum |
|-------|------|-------|----------------|------------|----------------------------------|-------------|---------|---------|
| | | | | | Lower Bound | Upper Bound | | |
| 1 | 95 | 53,22 | 34,841 | 3,575 | 46,12 | 60,32 | 1 | 108 |
| 2 | 286 | 92,00 | 62,208 | 3,678 | 84,76 | 99,24 | 3 | 250 |
| 3 | 96 | 63,56 | 38,308 | 3,910 | 55,80 | 71,32 | 6 | 140 |
| 4 | 287 | 62,51 | 38,180 | 2,254 | 58,07 | 66,94 | 4 | 129 |
| 5 | 96 | 60,81 | 36,987 | 3,775 | 53,32 | 68,31 | 8 | 124 |
| 6 | 4117 | 79,30 | 56,178 | ,876 | 77,59 | 81,02 | 1 | 363 |
| 7 | 3840 | 63,51 | 60,424 | ,975 | 61,60 | 65,42 | 0 | 463 |
| Total | 8817 | 71,64 | 57,942 | ,617 | 70,43 | 72,85 | 0 | 463 |

Test of Homogeneity of Variances

Calls

| Levene Statistic | df1 | df2 | Sig. |
|------------------|-----|------|------|
| 31,977 | 6 | 8810 | ,000 |

ANOVA

Calls

| | Sum of Squares | df | Mean Square | F | Sig. |
|----------------|----------------|------|-------------|--------|------|
| Between Groups | 687755,7 | 6 | 114625,951 | 34,932 | ,000 |
| Within Groups | 28909499 | 8810 | 3281,441 | | |
| Total | 29597255 | 8816 | | | |

A1.11 Korrelation von Uhrzeit und Calls

Korrelation zwischen acht und zwölf Uhr vormittags und Anrufe

Correlations

Correlations

| | | Uhrzeitcodiert | Calls |
|----------------|---------------------|----------------|--------|
| Uhrzeitcodiert | Pearson Correlation | 1 | ,496** |
| | Sig. (2-tailed) | . | ,000 |
| | N | 4827 | 4827 |
| Calls | Pearson Correlation | ,496** | 1 |
| | Sig. (2-tailed) | ,000 | . |
| | N | 4827 | 4827 |

** . Correlation is significant at the 0.01 level (2-tailed).

Korrelation zwischen 16 und 20 Uhr nachmittags und Anrufe

Correlations

Correlations

| | | Uhrzeitcodiert | Calls |
|----------------|---------------------|----------------|---------|
| Uhrzeitcodiert | Pearson Correlation | 1 | -,531** |
| | Sig. (2-tailed) | . | ,000 |
| | N | 4845 | 4845 |
| Calls | Pearson Correlation | -,531** | 1 |
| | Sig. (2-tailed) | ,000 | . |
| | N | 4845 | 4845 |

** . Correlation is significant at the 0.01 level (2-tailed).

A1.12 Untersuchung des Einflusses von Marketingmaßnahmen

**Untersuchung des Einflusses von Marketingmaßnahmen auf das Callverhalten
(Ausschnitt: vormittags von 7:00 bis 11:00 Uhr)**

T-Test

Group Statistics

| | TV | N | Mean | Std. Deviation | Std. Error Mean |
|-----------|----|-----|-------|----------------|-----------------|
| Differenz | 0 | 292 | 19,80 | 26,063 | 1,525 |
| | 1 | 81 | 23,42 | 25,948 | 2,883 |

Independent Samples Test

| | | Levene's Test for Equality of Variances | | t-test for Equality of Means | | | | | | |
|-----------|-----------------------------|---|------|------------------------------|---------|-----------------|-----------------|-----------------------|---|-------|
| | | F | Sig. | t | df | Sig. (2-tailed) | Mean Difference | Std. Error Difference | 95% Confidence Interval of the Difference | |
| | | | | | | | | | Lower | Upper |
| Differenz | Equal variances assumed | ,066 | ,798 | -1,108 | 371 | ,269 | -3,622 | 3,270 | -10,052 | 2,808 |
| | Equal variances not assumed | | | -1,110 | 128,281 | ,269 | -3,622 | 3,262 | -10,075 | 2,832 |

**Untersuchung des Einflusses von Marketingmaßnahmen auf das Callverhalten
(Ausschnitt: vormittags von 9:00 bis 9:15 Uhr)**

T-Test

Group Statistics

| | TV | N | Mean | Std. Deviation | Std. Error Mean |
|-----------|----|----|-------|----------------|-----------------|
| Differenz | 0 | 28 | 25,04 | 21,852 | 4,130 |
| | 1 | 16 | 37,94 | 34,146 | 8,536 |

Independent Samples Test

| | | Levene's Test for Equality of Variances | | t-test for Equality of Means | | | | | | |
|-----------|-----------------------------|---|------|------------------------------|--------|-----------------|-----------------|-----------------------|---|-------|
| | | F | Sig. | t | df | Sig. (2-tailed) | Mean Difference | Std. Error Difference | 95% Confidence Interval of the Difference | |
| | | | | | | | | | Lower | Upper |
| Differenz | Equal variances assumed | 5,548 | ,023 | -1,531 | 42 | ,133 | -12,902 | 8,429 | -29,912 | 4,108 |
| | Equal variances not assumed | | | -1,361 | 22,168 | ,187 | -12,902 | 9,483 | -32,559 | 6,756 |

A2 Netzwerkoptimierung

A2.1 Untersuchung der Struktur des Hidden Layers

Variation der Anzahl der verdeckten Neuronen

Codierung: z. B. HL10 = Hidden Layer mit 10 verdeckten Neuronen

F-Test zur Untersuchung der Varianzhomogenität mit anschließendem t-Test

| Zwei-Stichproben F-Test | | |
|--|-------------|-------------|
| | <i>HL10</i> | <i>HL15</i> |
| Mittelwert | 30,85482914 | 24,82301554 |
| Varianz | 449,4532704 | 199,228094 |
| Beobachtungen | 32 | 32 |
| Freiheitsgrade (df) | 31 | 31 |
| Prüfgröße (F) | 2,255973349 | |
| P(F<=f) einseitig | 0,013308434 | |
| Kritischer F-Wert bei einseitigem Test | 1,822133555 | |

| Zweistichproben t-Test unter der Annahme unterschiedlicher Varianzen | | |
|--|--------------|-------------|
| | <i>HL15</i> | <i>HL10</i> |
| Mittelwert | 24,82301554 | 30,85482914 |
| Varianz | 199,228094 | 449,4532704 |
| Beobachtungen | 32 | 32 |
| Hypothetische Differenz der Mittelwerte | 0 | |
| Freiheitsgrade (df) | 54 | |
| t-Statistik | -1,339698868 | |
| P(T<=t) einseitig | 0,092977103 | |
| Kritischer t-Wert bei einseitigem t-Test | 1,673565748 | |
| P(T<=t) zweiseitig | 0,185954206 | |
| Kritischer t-Wert bei zweiseitigem t-Test | 2,004881026 | |

| Zwei-Stichproben F-Test | | |
|--|-------------|-------------|
| | <i>HL11</i> | <i>HL15</i> |
| Mittelwert | 32,65335785 | 24,82301554 |
| Varianz | 579,8616157 | 199,228094 |
| Beobachtungen | 32 | 32 |
| Freiheitsgrade (df) | 31 | 31 |
| Prüfgröße (F) | 2,910541401 | |
| P(F<=f) einseitig | 0,001958264 | |
| Kritischer F-Wert bei einseitigem Test | 1,822133555 | |

| Zweistichproben t-Test unter der Annahme unterschiedlicher Varianzen | | |
|--|--------------|-------------|
| | HL15 | HL11 |
| Mittelwert | 24,82301554 | 32,65335785 |
| Varianz | 199,228094 | 579,8616157 |
| Beobachtungen | 32 | 32 |
| Hypothetische Differenz der Mittelwerte | 0 | |
| Freiheitsgrade (df) | 50 | |
| t-Statistik | -1,586945467 | |
| P(T<=t) einseitig | 0,059414814 | |
| Kritischer t-Wert bei einseitigem t-Test | 1,675905423 | |
| P(T<=t) zweiseitig | 0,118829627 | |
| Kritischer t-Wert bei zweiseitigem t-Test | 2,008559932 | |

| Zwei-Stichproben F-Test | | |
|--|-------------|-------------|
| | HL12 | HL15 |
| Mittelwert | 31,71775629 | 24,82301554 |
| Varianz | 510,346733 | 199,228094 |
| Beobachtungen | 32 | 32 |
| Freiheitsgrade (df) | 31 | 31 |
| Prüfgröße (F) | 2,561620316 | |
| P(F<=f) einseitig | 0,005350148 | |
| Kritischer F-Wert bei einseitigem Test | 1,822133555 | |

| Zweistichproben t-Test unter der Annahme unterschiedlicher Varianzen | | |
|--|-------------|-------------|
| | HL15 | HL12 |
| Mittelwert | 24,82301554 | 31,71775629 |
| Varianz | 199,228094 | 510,346733 |
| Beobachtungen | 32 | 32 |
| Hypothetische Differenz der Mittelwerte | 0 | |
| Freiheitsgrade (df) | 52 | |
| t-Statistik | -1,46417784 | |
| P(T<=t) einseitig | 0,074582497 | |
| Kritischer t-Wert bei einseitigem t-Test | 1,674688974 | |
| P(T<=t) zweiseitig | 0,149164995 | |
| Kritischer t-Wert bei zweiseitigem t-Test | 2,006645445 | |

| Zwei-Stichproben F-Test | | |
|--|-------------|-------------|
| | HL13 | HL15 |
| Mittelwert | 31,78219922 | 24,82301554 |
| Varianz | 454,2771988 | 199,228094 |
| Beobachtungen | 32 | 32 |
| Freiheitsgrade (df) | 31 | 31 |
| Prüfgröße (F) | 2,280186443 | |
| P(F<=f) einseitig | 0,012370623 | |
| Kritischer F-Wert bei einseitigem Test | 1,822133555 | |

| Zweistichproben t-Test unter der Annahme unterschiedlicher Varianzen | | |
|--|--------------|-------------|
| | HL15 | HL13 |
| Mittelwert | 24,82301554 | 31,78219922 |
| Varianz | 199,228094 | 454,2771988 |
| Beobachtungen | 32 | 32 |
| Hypothetische Differenz der Mittelwerte | 0 | |
| Freiheitsgrade (df) | 54 | |
| t-Statistik | -1,539957494 | |
| P(T<=t) einseitig | 0,064705323 | |
| Kritischer t-Wert bei einseitigem t-Test | 1,673565748 | |
| P(T<=t) zweiseitig | 0,129410646 | |
| Kritischer t-Wert bei zweiseitigem t-Test | 2,004881026 | |

| Zwei-Stichproben F-Test | | |
|--|-------------|-------------|
| | HL14 | HL15 |
| Mittelwert | 30,4977901 | 24,82301554 |
| Varianz | 455,0620571 | 199,228094 |
| Beobachtungen | 32 | 32 |
| Freiheitsgrade (df) | 31 | 31 |
| Prüfgröße (F) | 2,284125939 | |
| P(F<=f) einseitig | 0,012224572 | |
| Kritischer F-Wert bei einseitigem Test | 1,822133555 | |

| Zweistichproben t-Test unter der Annahme unterschiedlicher Varianzen | | |
|--|--------------|-------------|
| | HL15 | HL14 |
| Mittelwert | 24,82301554 | 30,4977901 |
| Varianz | 199,228094 | 455,0620571 |
| Beobachtungen | 32 | 32 |
| Hypothetische Differenz der Mittelwerte | 0 | |
| Freiheitsgrade (df) | 54 | |
| t-Statistik | -1,254984641 | |
| P(T<=t) einseitig | 0,107444295 | |
| Kritischer t-Wert bei einseitigem t-Test | 1,673565748 | |
| P(T<=t) zweiseitig | 0,214888591 | |
| Kritischer t-Wert bei zweiseitigem t-Test | 2,004881026 | |

| Zwei-Stichproben F-Test | | |
|--|-------------|-------------|
| | HL16 | HL15 |
| Mittelwert | 30,60530375 | 24,82301554 |
| Varianz | 457,4984725 | 199,228094 |
| Beobachtungen | 32 | 32 |
| Freiheitsgrade (df) | 31 | 31 |
| Prüfgröße (F) | 2,296355215 | |
| P(F<=f) einseitig | 0,011782356 | |
| Kritischer F-Wert bei einseitigem Test | 1,822133555 | |

| Zweistichproben t-Test unter der Annahme unterschiedlicher Varianzen | | |
|--|--------------|-------------|
| | HL15 | HL16 |
| Mittelwert | 24,82301554 | 30,60530375 |
| Varianz | 199,228094 | 457,4984725 |
| Beobachtungen | 32 | 32 |
| Hypothetische Differenz der Mittelwerte | 0 | |
| Freiheitsgrade (df) | 54 | |
| t-Statistik | -1,276387173 | |
| P(T<=t) einseitig | 0,103640471 | |
| Kritischer t-Wert bei einseitigem t-Test | 1,673565748 | |
| P(T<=t) zweiseitig | 0,207280943 | |
| Kritischer t-Wert bei zweiseitigem t-Test | 2,004881026 | |

| Zwei-Stichproben F-Test | | |
|--|-------------|-------------|
| | HL17 | HL15 |
| Mittelwert | 27,63673173 | 24,82301554 |
| Varianz | 385,0964612 | 199,228094 |
| Beobachtungen | 32 | 32 |
| Freiheitsgrade (df) | 31 | 31 |
| Prüfgröße (F) | 1,932942556 | |
| P(F<=f) einseitig | 0,035614155 | |
| Kritischer F-Wert bei einseitigem Test | 1,822133555 | |

| Zweistichproben t-Test unter der Annahme unterschiedlicher Varianzen | | |
|--|--------------|-------------|
| | HL15 | HL17 |
| Mittelwert | 24,82301554 | 27,63673173 |
| Varianz | 199,228094 | 385,0964612 |
| Beobachtungen | 32 | 32 |
| Hypothetische Differenz der Mittelwerte | 0 | |
| Freiheitsgrade (df) | 56 | |
| t-Statistik | -0,658458198 | |
| P(T<=t) einseitig | 0,256470953 | |
| Kritischer t-Wert bei einseitigem t-Test | 1,672522103 | |
| P(T<=t) zweiseitig | 0,512941907 | |
| Kritischer t-Wert bei zweiseitigem t-Test | 2,003239388 | |

| Zwei-Stichproben F-Test | | |
|--|-------------|-------------|
| | HL18 | HL15 |
| Mittelwert | 33,35886331 | 24,82301554 |
| Varianz | 568,345854 | 199,228094 |
| Beobachtungen | 32 | 32 |
| Freiheitsgrade (df) | 31 | 31 |
| Prüfgröße (F) | 2,852739504 | |
| P(F<=f) einseitig | 0,002306425 | |
| Kritischer F-Wert bei einseitigem Test | 1,822133555 | |

| Zweistichproben t-Test unter der Annahme unterschiedlicher Varianzen | | |
|--|--------------|-------------|
| | HL15 | HL18 |
| Mittelwert | 24,82301554 | 33,35886331 |
| Varianz | 199,228094 | 568,345854 |
| Beobachtungen | 32 | 32 |
| Hypothetische Differenz der Mittelwerte | 0 | |
| Freiheitsgrade (df) | 50 | |
| t-Statistik | -1,742856126 | |
| P(T<=t) einseitig | 0,043753141 | |
| Kritischer t-Wert bei einseitigem t-Test | 1,675905423 | |
| P(T<=t) zweiseitig | 0,087506281 | |
| Kritischer t-Wert bei zweiseitigem t-Test | 2,008559932 | |

| Zwei-Stichproben F-Test | | |
|--|-------------|-------------|
| | HL19 | HL15 |
| Mittelwert | 32,71139357 | 24,82301554 |
| Varianz | 580,1298778 | 199,228094 |
| Beobachtungen | 32 | 32 |
| Freiheitsgrade (df) | 31 | 31 |
| Prüfgröße (F) | 2,911887909 | |
| P(F<=f) einseitig | 0,00195084 | |
| Kritischer F-Wert bei einseitigem Test | 1,822133555 | |

| Zweistichproben t-Test unter der Annahme unterschiedlicher Varianzen | | |
|--|--------------|-------------|
| | HL15 | HL19 |
| Mittelwert | 24,82301554 | 32,71139357 |
| Varianz | 199,228094 | 580,1298778 |
| Beobachtungen | 32 | 32 |
| Hypothetische Differenz der Mittelwerte | 0 | |
| Freiheitsgrade (df) | 50 | |
| t-Statistik | -1,598432174 | |
| P(T<=t) einseitig | 0,058123949 | |
| Kritischer t-Wert bei einseitigem t-Test | 1,675905423 | |
| P(T<=t) zweiseitig | 0,116247897 | |
| Kritischer t-Wert bei zweiseitigem t-Test | 2,008559932 | |

| Zwei-Stichproben F-Test | | |
|--|-------------|-------------|
| | HL20 | HL15 |
| Mittelwert | 33,05211794 | 24,82301554 |
| Varianz | 535,4486921 | 199,228094 |
| Beobachtungen | 32 | 32 |
| Freiheitsgrade (df) | 31 | 31 |
| Prüfgröße (F) | 2,687616397 | |
| P(F<=f) einseitig | 0,003704342 | |
| Kritischer F-Wert bei einseitigem Test | 1,822133555 | |

| Zweistichproben t-Test unter der Annahme unterschiedlicher Varianzen | | |
|--|--------------|-------------|
| | HL15 | HL20 |
| Mittelwert | 24,82301554 | 33,05211794 |
| Varianz | 199,228094 | 535,4486921 |
| Beobachtungen | 32 | 32 |
| Hypothetische Differenz der Mittelwerte | 0 | |
| Freiheitsgrade (df) | 51 | |
| t-Statistik | -1,717430996 | |
| P(T<=t) einseitig | 0,045983933 | |
| Kritischer t-Wert bei einseitigem t-Test | 1,675284693 | |
| P(T<=t) zweiseitig | 0,091967866 | |
| Kritischer t-Wert bei zweiseitigem t-Test | 2,007582225 | |

A2.2 Verbesserung der Netzwerkperformance durch Optimierung der Codierung der Einflussvariablen „Feiertag/Wochenende“

| Anova: Einfaktorielle Varianzanalyse | | | | |
|--------------------------------------|--------|---------|-------------|-------------|
| ZUSAMMENFASSUNG | | | | |
| Gruppen | Anzahl | Summe | Mittelwert | Varianz |
| FE2 | 2107 | 1469700 | 697,5320361 | 2005295,304 |
| FE3 | 2107 | 1440367 | 683,6103465 | 1688128,945 |
| FE4 | 2107 | 1531023 | 726,6364499 | 1886971,106 |
| FE5 | 2107 | 1407053 | 667,7992406 | 1739881,903 |
| FE6 | 2107 | 192887 | 91,54579972 | 35321,97926 |
| FE7 | 2107 | 1484677 | 704,6402468 | 1831619,921 |
| FE8 | 2107 | 1464269 | 694,9544376 | 1746256,43 |

| ANOVA | | | | | | |
|-----------------------------------|--------------------|---------------------|----------------------------|---------------|-------------|-------------------|
| Streuungsursache | Quadratsummen (SS) | Freiheitsgrade (df) | Mittlere Quadratsumme (MS) | Prüfgröße (F) | P-Wert | kritischer F-Wert |
| Unterschiede zwischen den Gruppen | 663689000,3 | 6 | 110614833,4 | 70,81955115 | 2,33474E-87 | 2,099209695 |
| Innerhalb der Gruppen | 23025899591 | 14742 | 1561925,084 | | | |
| Gesamt | 23689588591 | 14748 | | | | |

A3 Überprüfung der Prämissen des Erlang C-Modells

A3.1 Analyse der Ankunftszeiten

Überprüfung homogener Poisson-Prozess

Übersicht der ermittelten kumulierten relativen Häufigkeiten:

| Montag | | | | |
|-----------------|---------------|------------------|----------------------------------|----------------------------------|
| 20040906 | | | | |
| | Anzahl | Kumulativ | kumul. rel. Häufigk. real | kumul. rel. Häufigk. erw. |
| | | | % | |
| 00:15 | 18 | 18 | 0,000885435 | 0 |
| 00:30 | 16 | 34 | 0,001672488 | 0,010526316 |
| 00:45 | 9 | 43 | 0,002115205 | 0,021052632 |
| 01:00 | 16 | 59 | 0,002902258 | 0,031578947 |
| 01:15 | 8 | 67 | 0,003295784 | 0,042105263 |
| 01:30 | 16 | 83 | 0,004082837 | 0,052631579 |
| 01:45 | 8 | 91 | 0,004476364 | 0,063157895 |
| 02:00 | 2 | 93 | 0,004574745 | 0,073684211 |
| 02:15 | 10 | 103 | 0,005066654 | 0,084210526 |
| 02:30 | 9 | 112 | 0,005509371 | 0,094736842 |
| 02:45 | 6 | 118 | 0,005804516 | 0,105263158 |
| 03:00 | 8 | 126 | 0,006198042 | 0,115789474 |
| 03:15 | 6 | 132 | 0,006493187 | 0,126315789 |
| 03:30 | 9 | 141 | 0,006935904 | 0,136842105 |
| 03:45 | 5 | 146 | 0,007181858 | 0,147368421 |
| 04:00 | 5 | 151 | 0,007427812 | 0,157894737 |
| 04:15 | 2 | 153 | 0,007526194 | 0,168421053 |
| 04:30 | 2 | 155 | 0,007624576 | 0,178947368 |
| 04:45 | 6 | 161 | 0,007919721 | 0,189473684 |
| 05:00 | 5 | 166 | 0,008165675 | 0,2 |
| 05:15 | 7 | 173 | 0,00851001 | 0,210526316 |
| 05:30 | 6 | 179 | 0,008805155 | 0,221052632 |
| 05:45 | 15 | 194 | 0,009543017 | 0,231578947 |
| 06:00 | 15 | 209 | 0,01028088 | 0,242105263 |
| 06:15 | 11 | 220 | 0,010821978 | 0,252631579 |
| 06:30 | 15 | 235 | 0,011559841 | 0,263157895 |
| 06:45 | 29 | 264 | 0,012986374 | 0,273684211 |
| 07:00 | 43 | 307 | 0,015101579 | 0,284210526 |
| 07:15 | 59 | 366 | 0,018003837 | 0,294736842 |
| 07:30 | 82 | 448 | 0,022037483 | 0,305263158 |
| 07:45 | 98 | 546 | 0,026858183 | 0,315789474 |
| 08:00 | 149 | 695 | 0,034187614 | 0,326315789 |
| 08:15 | 245 | 940 | 0,046239362 | 0,336842105 |
| 08:30 | 291 | 1231 | 0,060553889 | 0,347368421 |
| 08:45 | 331 | 1562 | 0,076836047 | 0,357894737 |
| 09:00 | 418 | 1980 | 0,097397806 | 0,368421053 |
| 09:15 | 441 | 2421 | 0,119090954 | 0,378947368 |
| 09:30 | 479 | 2900 | 0,142653352 | 0,389473684 |

| | | | | |
|-------|-----|-------|-------------|-------------|
| 09:45 | 504 | 3404 | 0,167445521 | 0,4 |
| 10:00 | 536 | 3940 | 0,193811796 | 0,410526316 |
| 10:15 | 507 | 4447 | 0,218751537 | 0,421052632 |
| 10:30 | 551 | 4998 | 0,245855674 | 0,431578947 |
| 10:45 | 564 | 5562 | 0,273599292 | 0,442105263 |
| 11:00 | 517 | 6079 | 0,299030941 | 0,452631579 |
| 11:15 | 562 | 6641 | 0,326676177 | 0,463157895 |
| 11:30 | 551 | 7192 | 0,353780314 | 0,473684211 |
| 11:45 | 509 | 7701 | 0,378818437 | 0,484210526 |
| 12:00 | 483 | 8184 | 0,402577599 | 0,494736842 |
| 12:15 | 485 | 8669 | 0,426435142 | 0,505263158 |
| 12:30 | 444 | 9113 | 0,448275862 | 0,515789474 |
| 12:45 | 394 | 9507 | 0,467657042 | 0,526315789 |
| 13:00 | 406 | 9913 | 0,487628511 | 0,536842105 |
| 13:15 | 401 | 10314 | 0,507354026 | 0,547368421 |
| 13:30 | 396 | 10710 | 0,526833587 | 0,557894737 |
| 13:45 | 442 | 11152 | 0,548575926 | 0,568421053 |
| 14:00 | 441 | 11593 | 0,570269074 | 0,578947368 |
| 14:15 | 473 | 12066 | 0,593536327 | 0,589473684 |
| 14:30 | 437 | 12503 | 0,615032712 | 0,6 |
| 14:45 | 460 | 12963 | 0,637660485 | 0,610526316 |
| 15:00 | 433 | 13396 | 0,658960106 | 0,621052632 |
| 15:15 | 462 | 13858 | 0,681686261 | 0,631578947 |
| 15:30 | 465 | 14323 | 0,704559988 | 0,642105263 |
| 15:45 | 439 | 14762 | 0,726154754 | 0,652631579 |
| 16:00 | 445 | 15207 | 0,748044665 | 0,663157895 |
| 16:15 | 422 | 15629 | 0,768803188 | 0,673684211 |
| 16:30 | 408 | 16037 | 0,788873039 | 0,684210526 |
| 16:45 | 367 | 16404 | 0,806926066 | 0,694736842 |
| 17:00 | 333 | 16737 | 0,823306606 | 0,705263158 |
| 17:15 | 291 | 17028 | 0,837621132 | 0,715789474 |
| 17:30 | 302 | 17330 | 0,852476757 | 0,726315789 |
| 17:45 | 265 | 17595 | 0,865512322 | 0,736842105 |
| 18:00 | 287 | 17882 | 0,879630085 | 0,747368421 |
| 18:15 | 215 | 18097 | 0,890206109 | 0,757894737 |
| 18:30 | 225 | 18322 | 0,901274042 | 0,768421053 |
| 18:45 | 178 | 18500 | 0,910030006 | 0,778947368 |
| 19:00 | 193 | 18693 | 0,919523833 | 0,789473684 |
| 19:15 | 168 | 18861 | 0,927787889 | 0,8 |
| 19:30 | 151 | 19012 | 0,935215702 | 0,810526316 |
| 19:45 | 144 | 19156 | 0,942299179 | 0,821052632 |
| 20:00 | 144 | 19300 | 0,949382655 | 0,831578947 |
| 20:15 | 135 | 19435 | 0,956023415 | 0,842105263 |
| 20:30 | 120 | 19555 | 0,961926312 | 0,852631579 |
| 20:45 | 96 | 19651 | 0,96664863 | 0,863157895 |
| 21:00 | 113 | 19764 | 0,972207192 | 0,873684211 |
| 21:15 | 107 | 19871 | 0,977470608 | 0,884210526 |
| 21:30 | 66 | 19937 | 0,980717202 | 0,894736842 |
| 21:45 | 60 | 19997 | 0,983668651 | 0,905263158 |
| 22:00 | 67 | 20064 | 0,986964435 | 0,915789474 |
| 22:15 | 54 | 20118 | 0,989620739 | 0,926315789 |

| | | | | |
|-------|----|-------|-------------|-------------|
| 22:30 | 42 | 20160 | 0,991686753 | 0,936842105 |
| 22:45 | 35 | 20195 | 0,993408431 | 0,947368421 |
| 23:00 | 33 | 20228 | 0,995031728 | 0,957894737 |
| 23:15 | 37 | 20265 | 0,996851788 | 0,968421053 |
| 23:30 | 24 | 20289 | 0,998032368 | 0,978947368 |
| 23:45 | 22 | 20311 | 0,999114565 | 0,989473684 |
| 00:00 | 18 | 20329 | 1 | 1 |

A3.2 Analyse der Servicezeiten

A3.2.1 Mittelwertvergleich der Gesprächszeiten bei Unterscheidung zwischen Tages- und Nachtstunden

Codierung: 1=Nachtstunden (20:00 – 8:00 Uhr); 2=Tagesstunden (8:00 – 20:00 Uhr)

Gesamtanalyse

Group Statistics

| | TAGnacht | N | Mean | Std. Deviation | Std. Error Mean |
|-------|----------|-------|-------|----------------|-----------------|
| t(ab) | 1,00 | 6734 | 45,37 | 35,420 | ,432 |
| | 2,00 | 57475 | 48,81 | 34,407 | ,144 |

Independent Samples Test

| | | Levene's Test for Equality of Variances | | t-test for Equality of Means | | | | | | |
|-------|-----------------------------|---|------|------------------------------|----------|-----------------|-----------------|-----------------------|---|--------|
| | | F | Sig. | t | df | Sig. (2-tailed) | Mean Difference | Std. Error Difference | 95% Confidence Interval of the Difference | |
| | | | | | | | | | Lower | Upper |
| t(ab) | Equal variances assumed | 40,177 | ,000 | -7,745 | 64207 | ,000 | -3,443 | ,445 | -4,314 | -2,572 |
| | Equal variances not assumed | | | -7,570 | 8292,272 | ,000 | -3,443 | ,455 | -4,335 | -2,551 |

t-Test unter Ausschluss der Servicezeiten von weniger als 10 Sekunden**T-Test****Group Statistics**

| | TAGnacht | N | Mean | Std. Deviation | Std. Error Mean |
|-------|----------|-------|-------|----------------|-----------------|
| t(ab) | 1,00 | 5972 | 50,54 | 34,317 | ,444 |
| | 2,00 | 54737 | 51,03 | 33,755 | ,144 |

Independent Samples Test

| | | Levene's Test for Equality of Variances | | t-test for Equality of Means | | | | | | |
|-------|-----------------------------|---|------|------------------------------|----------|-----------------|-----------------|-----------------------|---|-------|
| | | F | Sig. | t | df | Sig. (2-tailed) | Mean Difference | Std. Error Difference | 95% Confidence Interval of the Difference | |
| | | | | | | | | | Lower | Upper |
| t(ab) | Equal variances assumed | 21,249 | ,000 | -1,074 | 60707 | ,283 | -,495 | ,461 | -1,398 | ,408 |
| | Equal variances not assumed | | | -1,060 | 7289,242 | ,289 | -,495 | ,467 | -1,410 | ,420 |

Vergleich der Servicezeiten an Werktagen und an Wochenden

Durchschnittliche Gesprächszeiten an Werktagen:

| Werktags | t(ab) | Mittelwert | Standardabweichung | Anzahl |
|--------------------|-------|-------------|--------------------|--------|
| schicht in stunden | 1 | 40,93567251 | 36,23578082 | 1197 |
| | 2 | 40,87827076 | 38,91796721 | 879 |
| | 3 | 41,33558179 | 39,47622059 | 593 |
| | 4 | 41,20183486 | 82,57808897 | 436 |
| | 5 | 41,10353535 | 43,72621249 | 396 |
| | 6 | 36,7694859 | 29,53895335 | 603 |
| | 7 | 46,64028352 | 35,48686978 | 1693 |
| | 8 | 46,74970571 | 33,86880555 | 6796 |
| | 9 | 48,78478586 | 33,11906989 | 21388 |
| | 10 | 49,24364723 | 30,79998004 | 34119 |
| | 11 | 49,69772187 | 32,41902516 | 38716 |
| | 12 | 49,59414863 | 33,69977433 | 38726 |
| | 13 | 49,03555319 | 34,94276992 | 31924 |
| | 14 | 48,99109688 | 34,09417088 | 31225 |
| | 15 | 48,78962279 | 37,06163074 | 32475 |
| | 16 | 49,38535846 | 37,12032144 | 31677 |
| | 17 | 49,16810123 | 33,79009946 | 27186 |
| | 18 | 48,9660522 | 36,87554019 | 21916 |
| | 19 | 48,20563796 | 38,90687338 | 16247 |
| | 20 | 49,13687469 | 37,97349276 | 12274 |
| | 21 | 48,72112019 | 38,98907729 | 8570 |
| | 22 | 48,3241051 | 38,33314998 | 5671 |
| | 23 | 45,48341102 | 39,6248409 | 3647 |
| | 24 | 46,36188731 | 42,6314547 | 2183 |

Durchschnittliche Gesprächszeiten am Wochenende:

| Wochenende | | t(ab) Mittelwert | Standardabweichung | Anzahl |
|--------------------|----|---------------------|--------------------|--------|
| schicht in stunden | 1 | 43,42468619 | 37,54976562 | 956 |
| | 2 | 41,96966019 | 42,86941149 | 824 |
| | 3 | 39,39434524 | 31,4238013 | 672 |
| | 4 | 39,76908023 | 38,47608759 | 511 |
| | 5 | 38,43360996 | 31,63613212 | 482 |
| | 6 | 38,45272206 | 32,67184761 | 349 |
| | 7 | 39,78231293 | 33,1375285 | 294 |
| | 8 | 42,9664311 | 46,53247723 | 566 |
| | 9 | 48,05105348 | 77,02942731 | 1234 |
| | 10 | 46,72934596 | 33,66239133 | 2324 |
| | 11 | 48,42062044 | 35,56510325 | 3288 |
| | 12 | 47,48708983 | 33,78041931 | 3718 |
| | 13 | 46,96119792 | 34,13744654 | 3840 |
| | 14 | 47,224644 | 40,48026849 | 3441 |
| | 15 | 47,45133011 | 35,40939094 | 3308 |
| | 16 | 44,74558413 | 38,16303543 | 3227 |
| | 17 | 43,80760626 | 32,21863341 | 3129 |
| | 18 | 43,84716692 | 32,11126269 | 3265 |
| | 19 | 46,18695107 | 35,74604749 | 3188 |
| | 20 | 45,41470311 | 33,22134305 | 3183 |
| | 21 | 46,71478599 | 35,62625474 | 2570 |
| | 22 | 45,71510297 | 64,42827742 | 1748 |
| | 23 | 42,21332276 | 33,44191382 | 1261 |
| | 24 | 44,33542977 | 77,6633077 | 954 |

Vorgeschalteter F-Test zur Prüfung der Varianzhomogenität:

| | f-Test | funten | foben | |
|----|-------------|-------------|-------------|----------------|
| 1 | 0,93123821 | 0,886973606 | 1,128356963 | nicht ablehnen |
| 2 | 0,824148082 | 0,874218031 | 1,144218942 | ablehnen |
| 3 | 1,578169675 | 0,854854409 | 1,168882768 | ablehnen |
| 4 | 4,606253623 | 0,8337806 | 1,197775212 | ablehnen |
| 5 | 1,910367674 | 0,827502511 | 1,206322153 | ablehnen |
| 6 | 0,817415402 | 0,831485103 | 1,208372069 | ablehnen |
| 7 | 1,146819733 | 0,843530579 | 1,198618094 | nicht ablehnen |
| 8 | 0,529770065 | 0,88842933 | 1,132724137 | ablehnen |
| 9 | 0,18485999 | 0,923372045 | 1,086216894 | ablehnen |
| 10 | 0,837164765 | 0,943021883 | 1,062078869 | ablehnen |
| 11 | 0,830905733 | 0,95139896 | 1,052224086 | ablehnen |
| 12 | 0,995231041 | 0,953965129 | 1,049249798 | nicht ablehnen |
| 13 | 1,047737748 | 0,954174517 | 1,048962028 | nicht ablehnen |
| 14 | 0,709371112 | 0,951898116 | 1,051591481 | ablehnen |
| 15 | 1,09549938 | 0,951160262 | 1,052460341 | ablehnen |
| 16 | 0,946101292 | 0,950572066 | 1,053139354 | ablehnen |
| 17 | 1,099929144 | 0,949528012 | 1,054315968 | ablehnen |
| 18 | 1,318748611 | 0,949800238 | 1,053922727 | ablehnen |

| | | | | |
|----|-------------|-------------|-------------|----------|
| 19 | 1,184667863 | 0,948175316 | 1,055693755 | ablehnen |
| 20 | 1,306552057 | 0,94677377 | 1,057176569 | ablehnen |
| 21 | 1,197693181 | 0,940044931 | 1,06490905 | ablehnen |
| 22 | 0,353994062 | 0,927655286 | 1,079651035 | ablehnen |
| 23 | 1,403953798 | 0,914296194 | 1,095953106 | ablehnen |
| 24 | 0,301320402 | 0,8989538 | 1,11496945 | ablehnen |

t-Test zum Vergleich der Mittelwerte:

| Stunde | t-test | z_unten | z_oben | Entscheidung |
|--------|--------------|--------------|-------------|----------------|
| 1 | -1,552056085 | -1,959962787 | 1,959962787 | nicht ablehnen |
| 2 | -0,548899554 | -1,959962787 | 1,959962787 | nicht ablehnen |
| 3 | 0,959015619 | -1,959962787 | 1,959962787 | nicht ablehnen |
| 4 | 0,332773257 | -1,959962787 | 1,959962787 | nicht ablehnen |
| 5 | 1,01607884 | -1,959962787 | 1,959962787 | nicht ablehnen |
| 6 | -0,792991039 | -1,959962787 | 1,959962787 | nicht ablehnen |
| 7 | 3,240499661 | -1,959962787 | 1,959962787 | ablehnen |
| 8 | 1,892972848 | -1,959962787 | 1,959962787 | nicht ablehnen |
| 9 | 0,332839483 | -1,959962787 | 1,959962787 | nicht ablehnen |
| 10 | 3,502258323 | -1,959962787 | 1,959962787 | ablehnen |
| 11 | 1,990034381 | -1,959962787 | 1,959962787 | ablehnen |
| 12 | 3,633709564 | -1,959962787 | 1,959962787 | ablehnen |
| 13 | 3,548486468 | -1,959962787 | 1,959962787 | ablehnen |
| 14 | 2,465226464 | -1,959962787 | 1,959962787 | ablehnen |
| 15 | 2,061782834 | -1,959962787 | 1,959962787 | ablehnen |
| 16 | 6,595878237 | -1,959962787 | 1,959962787 | ablehnen |
| 17 | 8,76831567 | -1,959962787 | 1,959962787 | ablehnen |
| 18 | 8,327405479 | -1,959962787 | 1,959962787 | ablehnen |
| 19 | 2,872197425 | -1,959962787 | 1,959962787 | ablehnen |
| 20 | 5,463052693 | -1,959962787 | 1,959962787 | ablehnen |
| 21 | 2,448854969 | -1,959962787 | 1,959962787 | ablehnen |
| 22 | 1,607609879 | -1,959962787 | 1,959962787 | nicht ablehnen |
| 23 | 2,849042294 | -1,959962787 | 1,959962787 | ablehnen |
| 24 | 0,757589239 | -1,959962787 | 1,959962787 | nicht ablehnen |

A3.2.2 Analyse stationärer Servicezeiten innerhalb der Stundenintervalle

Die Stundenintervalle werden weiter zerlegt in vier 15 Minutenintervalle und die Mittelwertunterschiede der Calleingänge in diesen Viertelstundenintervallen werden anschließend stundenweise miteinander durch eine Varianzanalyse überprüft:

schicht in stunden = 1,00

ONEWAY ANOVA(a)

t(ab)

| | Quadratsumme | df | Mittel der Quadrate | F | Signifikanz |
|-----------------------|--------------|----|---------------------|-------|-------------|
| Zwischen den Gruppen | 3122,811 | 3 | 1040,937 | 1,363 | ,263 |
| Innerhalb der Gruppen | 42760,122 | 56 | 763,574 | | |
| Gesamt | 45882,933 | 59 | | | |

a schicht in stunden = 1,00

schicht in stunden = 2,00

ONEWAY ANOVA(a)

t(ab)

| | Quadratsumme | df | Mittel der Quadrate | F | Signifikanz |
|-----------------------|--------------|----|---------------------|------|-------------|
| Zwischen den Gruppen | 3028,840 | 3 | 1009,613 | ,864 | ,467 |
| Innerhalb der Gruppen | 47909,738 | 41 | 1168,530 | | |
| Gesamt | 50938,578 | 44 | | | |

a schicht in stunden = 2,00

schicht in stunden = 3,00

ONEWAY ANOVA(a)

t(ab)

| | Quadratsumme | df | Mittel der Quadrate | F | Signifikanz |
|-----------------------|--------------|----|---------------------|------|-------------|
| Zwischen den Gruppen | 3936,558 | 3 | 1312,186 | ,704 | ,557 |
| Innerhalb der Gruppen | 57760,014 | 31 | 1863,226 | | |
| Gesamt | 61696,571 | 34 | | | |

a schicht in stunden = 3,00

schicht in stunden = 4,00

ONEWAY ANOVA(a)

t(ab)

| | Quadratsumme | df | Mittel der Quadrate | F | Signifikanz |
|-----------------------|--------------|----|---------------------|-------|-------------|
| Zwischen den Gruppen | 6684,244 | 3 | 2228,081 | 3,627 | ,026 |
| Innerhalb der Gruppen | 16587,949 | 27 | 614,368 | | |
| Gesamt | 23272,194 | 30 | | | |

a schicht in stunden = 4,00

schicht in stunden = 5,00

ONEWAY ANOVA(a)

t(ab)

| | Quadratsumme | df | Mittel der Quadrate | F | Signifikanz |
|-----------------------|--------------|----|---------------------|------|-------------|
| Zwischen den Gruppen | 1207,833 | 3 | 402,611 | ,585 | ,636 |
| Innerhalb der Gruppen | 8256,167 | 12 | 688,014 | | |
| Gesamt | 9464,000 | 15 | | | |

a schicht in stunden = 5,00

schicht in stunden = 6,00

ONEWAY ANOVA(a)

t(ab)

| | Quadratsumme | df | Mittel der Quadrate | F | Signifikanz |
|-----------------------|--------------|----|---------------------|------|-------------|
| Zwischen den Gruppen | 1072,170 | 3 | 357,390 | ,671 | ,580 |
| Innerhalb der Gruppen | 10122,700 | 19 | 532,774 | | |
| Gesamt | 11194,870 | 22 | | | |

a schicht in stunden = 6,00

schicht in stunden = 7,00

ONEWAY ANOVA(a)

t(ab)

| | Quadratsumme | df | Mittel der Quadrate | F | Signifikanz |
|-----------------------|--------------|----|---------------------|------|-------------|
| Zwischen den Gruppen | 2747,747 | 3 | 915,916 | ,705 | ,552 |
| Innerhalb der Gruppen | 84422,891 | 65 | 1298,814 | | |
| Gesamt | 87170,638 | 68 | | | |

a schicht in stunden = 7,00

schicht in stunden = 8,00

ONEWAY ANOVA(a)

t(ab)

| | Quadratsumme | df | Mittel der Quadrate | F | Signifikanz |
|-----------------------|--------------|-----|---------------------|------|-------------|
| Zwischen den Gruppen | 463,111 | 3 | 154,370 | ,125 | ,945 |
| Innerhalb der Gruppen | 433035,220 | 350 | 1237,243 | | |
| Gesamt | 433498,331 | 353 | | | |

a schicht in stunden = 8,00

schicht in stunden = 9,00

ONEWAY ANOVA(a)

t(ab)

| | Quadratsumme | df | Mittel der Quadrate | F | Signifikanz |
|-----------------------|--------------|------|---------------------|-------|-------------|
| Zwischen den Gruppen | 4489,135 | 3 | 1496,378 | 1,608 | ,186 |
| Innerhalb der Gruppen | 984549,517 | 1058 | 930,576 | | |
| Gesamt | 989038,652 | 1061 | | | |

a schicht in stunden = 9,00

schicht in stunden = 10,00

ONEWAY ANOVA(a)

t(ab)

| | Quadratsumme | df | Mittel der Quadrate | F | Signifikanz |
|-----------------------|--------------|------|---------------------|------|-------------|
| Zwischen den Gruppen | 431,926 | 4 | 107,982 | ,129 | ,972 |
| Innerhalb der Gruppen | 1504664,108 | 1792 | 839,656 | | |
| Gesamt | 1505096,035 | 1796 | | | |

a schicht in stunden = 10,00

schicht in stunden = 11,00

ONEWAY ANOVA(a)

t(ab)

| | Quadratsumme | df | Mittel der Quadrate | F | Signifikanz |
|-----------------------|--------------|------|---------------------|-------|-------------|
| Zwischen den Gruppen | 6931,837 | 3 | 2310,612 | 1,992 | ,113 |
| Innerhalb der Gruppen | 2280385,483 | 1966 | 1159,911 | | |
| Gesamt | 2287317,320 | 1969 | | | |

a schicht in stunden = 11,00

schicht in stunden = 12,00

ONEWAY ANOVA(a)

t(ab)

| | Quadratsumme | df | Mittel der Quadrate | F | Signifikanz |
|-----------------------|--------------|------|---------------------|-------|-------------|
| Zwischen den Gruppen | 5263,564 | 3 | 1754,521 | 1,733 | ,158 |
| Innerhalb der Gruppen | 2045211,717 | 2020 | 1012,481 | | |
| Gesamt | 2050475,280 | 2023 | | | |

schicht in stunden = 13,00

ONEWAY ANOVA(a)

t(ab)

| | Quadratsumme | df | Mittel der Quadrate | F | Signifikanz |
|-----------------------|--------------|------|---------------------|-------|-------------|
| Zwischen den Gruppen | 12772,926 | 3 | 4257,642 | 2,564 | ,053 |
| Innerhalb der Gruppen | 2673043,052 | 1610 | 1660,275 | | |
| Gesamt | 2685815,978 | 1613 | | | |

a schicht in stunden = 13,00

schicht in stunden = 14,00

ONEWAY ANOVA(a)

t(ab)

| | Quadratsumme | df | Mittel der Quadrate | F | Signifikanz |
|-----------------------|--------------|------|---------------------|------|-------------|
| Zwischen den Gruppen | 1225,311 | 4 | 306,328 | ,299 | ,879 |
| Innerhalb der Gruppen | 1660695,126 | 1622 | 1023,856 | | |
| Gesamt | 1661920,438 | 1626 | | | |

a schicht in stunden = 14,00

schicht in stunden = 15,00

ONEWAY ANOVA(a)

t(ab)

| | Quadratsumme | df | Mittel der Quadrate | F | Signifikanz |
|-----------------------|--------------|------|---------------------|-------|-------------|
| Zwischen den Gruppen | 27071,043 | 3 | 9023,681 | 1,803 | ,145 |
| Innerhalb der Gruppen | 8358907,779 | 1670 | 5005,334 | | |
| Gesamt | 8385978,822 | 1673 | | | |

a schicht in stunden = 15,00

schicht in stunden = 16,00**ONEWAY ANOVA(a)**

t(ab)

| | Quadratsumme | df | Mittel der Quadrate | F | Signifikanz |
|-----------------------|--------------|------|---------------------|------|-------------|
| Zwischen den Gruppen | 3165,979 | 4 | 791,495 | ,592 | ,669 |
| Innerhalb der Gruppen | 2208820,156 | 1651 | 1337,868 | | |
| Gesamt | 2211986,135 | 1655 | | | |

a schicht in stunden = 16,00

schicht in stunden = 17,00**ONEWAY ANOVA(a)**

t(ab)

| | Quadratsumme | df | Mittel der Quadrate | F | Signifikanz |
|-----------------------|--------------|------|---------------------|-------|-------------|
| Zwischen den Gruppen | 3967,465 | 3 | 1322,488 | 1,365 | ,252 |
| Innerhalb der Gruppen | 1505889,822 | 1554 | 969,041 | | |
| Gesamt | 1509857,287 | 1557 | | | |

a schicht in stunden = 17,00

schicht in stunden = 18,00**ONEWAY ANOVA(a)**

t(ab)

| | Quadratsumme | df | Mittel der Quadrate | F | Signifikanz |
|-----------------------|--------------|------|---------------------|-------|-------------|
| Zwischen den Gruppen | 6095,167 | 4 | 1523,792 | 1,102 | ,354 |
| Innerhalb der Gruppen | 1685441,382 | 1219 | 1382,643 | | |
| Gesamt | 1691536,548 | 1223 | | | |

a schicht in stunden = 18,00

schicht in stunden = 19,00**ONEWAY ANOVA(a)**

t(ab)

| | Quadratsumme | df | Mittel der Quadrate | F | Signifikanz |
|-----------------------|--------------|-----|---------------------|------|-------------|
| Zwischen den Gruppen | 3102,512 | 3 | 1034,171 | ,829 | ,478 |
| Innerhalb der Gruppen | 1070852,983 | 858 | 1248,080 | | |
| Gesamt | 1073955,495 | 861 | | | |

schicht in stunden = 20,00

ONEWAY ANOVA(a)

t(ab)

| | Quadratsumme | df | Mittel der Quadrate | F | Signifikanz |
|-----------------------|--------------|-----|---------------------|------|-------------|
| Zwischen den Gruppen | 3010,520 | 3 | 1003,507 | ,782 | ,504 |
| Innerhalb der Gruppen | 784267,733 | 611 | 1283,581 | | |
| Gesamt | 787278,254 | 614 | | | |

a schicht in stunden = 20,00

schicht in stunden = 21,00

ONEWAY ANOVA(a)

t(ab)

| | Quadratsumme | df | Mittel der Quadrate | F | Signifikanz |
|-----------------------|--------------|-----|---------------------|------|-------------|
| Zwischen den Gruppen | 3110,791 | 3 | 1036,930 | ,709 | ,547 |
| Innerhalb der Gruppen | 693681,645 | 474 | 1463,463 | | |
| Gesamt | 696792,435 | 477 | | | |

a schicht in stunden = 21,00

schicht in stunden = 22,00

ONEWAY ANOVA(a)

t(ab)

| | Quadratsumme | df | Mittel der Quadrate | F | Signifikanz |
|-----------------------|--------------|-----|---------------------|-------|-------------|
| Zwischen den Gruppen | 7819,517 | 3 | 2606,506 | 1,393 | ,245 |
| Innerhalb der Gruppen | 570745,046 | 305 | 1871,295 | | |
| Gesamt | 578564,563 | 308 | | | |

a schicht in stunden = 22,00

schicht in stunden = 23,00

ONEWAY ANOVA(a)

t(ab)

| | Quadratsumme | df | Mittel der Quadrate | F | Signifikanz |
|-----------------------|--------------|-----|---------------------|-------|-------------|
| Zwischen den Gruppen | 2954,392 | 3 | 984,797 | 1,059 | ,368 |
| Innerhalb der Gruppen | 158128,413 | 170 | 930,167 | | |
| Gesamt | 161082,805 | 173 | | | |

a schicht in stunden = 23,00

schicht in stunden = 24,00

ONEWAY ANOVA(a)

t(ab)

| | Quadratsumme | df | Mittel der Quadrate | F | Signifikanz |
|-----------------------|--------------|-----|---------------------|-------|-------------|
| Zwischen den Gruppen | 8177,832 | 3 | 2725,944 | 1,531 | ,210 |
| Innerhalb der Gruppen | 204694,454 | 115 | 1779,952 | | |
| Gesamt | 212872,286 | 118 | | | |

a schicht in stunden = 24,00

A4 Simulationsstudie

A4.1 Übersicht der Simulationsergebnisse

In den nachfolgenden Tabellen kann die optimale Anzahl der Operatoren abgelesen werden, wenn zum einen als Maßstab eine durchschnittliche Wartezeit in der Warteschleife von 20 Sekunden angesetzt wird und zum anderen, wenn das Kriterium einer 80%-igen Agentenauslastung zu Grunde gelegt wird. Des Weiteren werden die Ergebnisse aufgeschlüsselt nach den unterschiedlichen Ausgangsverteilungen für die Ankunfts- und Servicezeitraten.

Montag

| Gamma/Gamma/c | Auslastung (80%) | |
|--|-------------------------|-------------------------|
| Uhrzeit (jeweils von (t-1) bis (t)) | Wartezeit | Auslastung (80%) |
| 1 | 2 | 1 |
| 2 | 2 | 1 |
| 3 | 1 | 1 |
| 4 | 1 | 1 |
| 5 | 1 | 1 |
| 6 | 1 | 1 |
| 7 | 3 | 2 |
| 8 | 7 | 7 |
| 9 | 20 | 24 |
| 10 | 33 | 39 |
| 11 | 38 | 45 |
| 12 | 26 | 44 |
| 13 | 29 | 34 |
| 14 | 29 | 39 |
| 15 | 30 | 37 |
| 16 | 31 | 37 |
| 17 | 25 | 30 |
| 18 | 19 | 22 |
| 19 | 14 | 16 |
| 20 | 11 | 12 |
| 21 | 8 | 9 |
| 22 | 6 | 5 |
| 23 | 4 | 4 |
| 24 | 3 | 2 |

Dienstag bis Freitag

| Gamma/LNV/c | Wartezeit | Auslastung (80%) |
|-------------|-----------|---------------------|
| 1 | 3 | 2 |
| 2 | 3 | 1 |
| 3 | 2 | 1 |
| 4 | 2 | 1 |
| 5 | 2 | 1 |
| 6 | 2 | 1 |
| 7 | 4 | 2 |
| 8 | 7 | 6 |
| 9 | 19 | 19 |
| 10 | 32 | 29 |
| 11 | 35 | 36 |
| 12 | 34 | 36 |
| 13 | 29 | 32 |
| 14 | 27 | 29 |
| 15 | 29 | 29 |
| 16 | 28 | 28 |
| 17 | 25 | 25 |
| 18 | 21 | 21 |
| 19 | 16 | 17 |
| 20 | 14 | 12 |
| 21 | 9 | 9 |
| 22 | 7 | 6 |
| 23 | 6 | 4 |
| 24 | 4 | 3 |

Samstag

| Gamma/Gamma/c | Wartezeit | Auslastung (80%) |
|---------------|-----------|---------------------|
| 1 | 3 | 2 |
| 2 | 2 | 2 |
| 3 | 2 | 1 |
| 4 | 2 | 1 |
| 5 | 2 | 1 |
| 6 | 2 | 1 |
| 7 | 2 | 1 |
| 8 | 3 | 2 |
| 9 | 4 | 4 |
| 10 | 8 | 9 |
| 11 | 11 | 12 |
| 12 | 12 | 13 |
| 13 | 12 | 13 |
| 14 | 10 | 11 |
| 15 | 10 | 11 |
| 16 | 9 | 9 |
| 17 | 8 | 9 |
| 18 | 8 | 9 |
| 19 | 8 | 9 |
| 20 | 8 | 8 |

| | | |
|----|---|---|
| 21 | 7 | 7 |
| 22 | 5 | 5 |
| 23 | 4 | 4 |
| 24 | 3 | 4 |

Sonntag

| Gamma/Gamma/c | Wartezeit | Auslastung (80%) |
|---------------|-----------|------------------|
| 1 | 3 | 2 |
| 2 | 3 | 2 |
| 3 | 2 | 2 |
| 4 | 2 | 2 |
| 5 | 2 | 1 |
| 6 | 2 | 1 |
| 7 | 2 | 1 |
| 8 | 2 | 1 |
| 9 | 3 | 2 |
| 10 | 4 | 4 |
| 11 | 5 | 5 |
| 12 | 6 | 7 |
| 13 | 7 | 7 |
| 14 | 7 | 7 |
| 15 | 7 | 7 |
| 16 | 6 | 7 |
| 17 | 6 | 6 |
| 18 | 7 | 7 |
| 19 | 7 | 7 |
| 20 | 7 | 7 |
| 21 | 6 | 6 |
| 22 | 4 | 4 |
| 23 | 3 | 3 |
| 24 | 3 | 2 |

A4.2 Idle-Time sonntags

Nachfolgend sind die Idle-Zeiten der Agenten (in %), bezogen auf jeweils 15-Minuten-Intervalle, aufgelistet:

| | | | |
|-------|---------------------------|------|--------|
| 00:15 | Summe von Freie Zeit | 3463 | 76,96% |
| | Summe von Anmeldungsdauer | 4500 | |
| 00:30 | Summe von Freie Zeit | 3378 | 75,07% |
| | Summe von Anmeldungsdauer | 4500 | |
| 00:45 | Summe von Freie Zeit | 1951 | 54,19% |
| | Summe von Anmeldungsdauer | 3600 | |
| 01:00 | Summe von Freie Zeit | 1630 | 45,28% |
| | Summe von Anmeldungsdauer | 3600 | |
| 01:15 | Summe von Freie Zeit | 2721 | 75,58% |
| | Summe von Anmeldungsdauer | 3600 | |
| 01:30 | Summe von Freie Zeit | 2281 | 62,99% |
| | Summe von Anmeldungsdauer | 3621 | |

| | | | |
|-------|---------------------------|------|--------|
| 01:45 | Summe von Freie Zeit | 1175 | 45,65% |
| | Summe von Anmeldungsdauer | 2574 | |
| 02:00 | Summe von Freie Zeit | 1352 | 54,23% |
| | Summe von Anmeldungsdauer | 2493 | |
| 02:15 | Summe von Freie Zeit | 1657 | 61,37% |
| | Summe von Anmeldungsdauer | 2700 | |
| 02:30 | Summe von Freie Zeit | 1703 | 63,07% |
| | Summe von Anmeldungsdauer | 2700 | |
| 02:45 | Summe von Freie Zeit | 2031 | 75,22% |
| | Summe von Anmeldungsdauer | 2700 | |
| 03:00 | Summe von Freie Zeit | 2120 | 77,26% |
| | Summe von Anmeldungsdauer | 2744 | |
| 03:15 | Summe von Freie Zeit | 1060 | 58,89% |
| | Summe von Anmeldungsdauer | 1800 | |
| 03:30 | Summe von Freie Zeit | 1127 | 62,61% |
| | Summe von Anmeldungsdauer | 1800 | |
| 03:45 | Summe von Freie Zeit | 1209 | 67,17% |
| | Summe von Anmeldungsdauer | 1800 | |
| 04:00 | Summe von Freie Zeit | 587 | 32,61% |
| | Summe von Anmeldungsdauer | 1800 | |
| 04:15 | Summe von Freie Zeit | 1644 | 91,33% |
| | Summe von Anmeldungsdauer | 1800 | |
| 04:30 | Summe von Freie Zeit | 1047 | 58,17% |
| | Summe von Anmeldungsdauer | 1800 | |
| 04:45 | Summe von Freie Zeit | 1042 | 57,89% |
| | Summe von Anmeldungsdauer | 1800 | |
| 05:00 | Summe von Freie Zeit | 1062 | 59,00% |
| | Summe von Anmeldungsdauer | 1800 | |
| 05:15 | Summe von Freie Zeit | 1102 | 61,22% |
| | Summe von Anmeldungsdauer | 1800 | |
| 05:30 | Summe von Freie Zeit | 1140 | 63,33% |
| | Summe von Anmeldungsdauer | 1800 | |
| 05:45 | Summe von Freie Zeit | 1265 | 70,28% |
| | Summe von Anmeldungsdauer | 1800 | |
| 06:00 | Summe von Freie Zeit | 1388 | 56,77% |
| | Summe von Anmeldungsdauer | 2445 | |
| 06:15 | Summe von Freie Zeit | 2177 | 83,99% |
| | Summe von Anmeldungsdauer | 2592 | |
| 06:30 | Summe von Freie Zeit | 1409 | 52,19% |
| | Summe von Anmeldungsdauer | 2700 | |
| 06:45 | Summe von Freie Zeit | 1442 | 53,41% |
| | Summe von Anmeldungsdauer | 2700 | |
| 07:00 | Summe von Freie Zeit | 1803 | 60,14% |
| | Summe von Anmeldungsdauer | 2998 | |
| 07:15 | Summe von Freie Zeit | 2533 | 70,36% |
| | Summe von Anmeldungsdauer | 3600 | |
| 07:30 | Summe von Freie Zeit | 2232 | 62,00% |
| | Summe von Anmeldungsdauer | 3600 | |
| 07:45 | Summe von Freie Zeit | 2468 | 68,56% |
| | Summe von Anmeldungsdauer | 3600 | |
| 08:00 | Summe von Freie Zeit | 2734 | 74,68% |
| | Summe von Anmeldungsdauer | 3661 | |

| | | | |
|-------|---------------------------|-------|--------|
| 08:15 | Summe von Freie Zeit | 2655 | 59,00% |
| | Summe von Anmeldungsdauer | 4500 | |
| 08:30 | Summe von Freie Zeit | 2297 | 45,91% |
| | Summe von Anmeldungsdauer | 5003 | |
| 08:45 | Summe von Freie Zeit | 2995 | 55,46% |
| | Summe von Anmeldungsdauer | 5400 | |
| 09:00 | Summe von Freie Zeit | 2831 | 50,59% |
| | Summe von Anmeldungsdauer | 5596 | |
| 09:15 | Summe von Freie Zeit | 2728 | 43,30% |
| | Summe von Anmeldungsdauer | 6300 | |
| 09:30 | Summe von Freie Zeit | 2359 | 34,06% |
| | Summe von Anmeldungsdauer | 6925 | |
| 09:45 | Summe von Freie Zeit | 2492 | 31,58% |
| | Summe von Anmeldungsdauer | 7891 | |
| 10:00 | Summe von Freie Zeit | 3576 | 44,15% |
| | Summe von Anmeldungsdauer | 8100 | |
| 10:15 | Summe von Freie Zeit | 4671 | 57,67% |
| | Summe von Anmeldungsdauer | 8100 | |
| 10:30 | Summe von Freie Zeit | 4793 | 55,96% |
| | Summe von Anmeldungsdauer | 8565 | |
| 10:45 | Summe von Freie Zeit | 3733 | 41,48% |
| | Summe von Anmeldungsdauer | 9000 | |
| 11:00 | Summe von Freie Zeit | 4566 | 50,73% |
| | Summe von Anmeldungsdauer | 9001 | |
| 11:15 | Summe von Freie Zeit | 4596 | 47,24% |
| | Summe von Anmeldungsdauer | 9730 | |
| 11:30 | Summe von Freie Zeit | 5654 | 55,99% |
| | Summe von Anmeldungsdauer | 10099 | |
| 11:45 | Summe von Freie Zeit | 3858 | 35,72% |
| | Summe von Anmeldungsdauer | 10800 | |
| 12:00 | Summe von Freie Zeit | 4680 | 43,33% |
| | Summe von Anmeldungsdauer | 10800 | |
| 12:15 | Summe von Freie Zeit | 4816 | 41,65% |
| | Summe von Anmeldungsdauer | 11564 | |
| 12:30 | Summe von Freie Zeit | 5027 | 42,54% |
| | Summe von Anmeldungsdauer | 11817 | |
| 12:45 | Summe von Freie Zeit | 3425 | 32,31% |
| | Summe von Anmeldungsdauer | 10601 | |
| 13:00 | Summe von Freie Zeit | 4814 | 44,57% |
| | Summe von Anmeldungsdauer | 10800 | |
| 13:15 | Summe von Freie Zeit | 4151 | 38,54% |
| | Summe von Anmeldungsdauer | 10770 | |
| 13:30 | Summe von Freie Zeit | 3648 | 33,64% |
| | Summe von Anmeldungsdauer | 10843 | |
| 13:45 | Summe von Freie Zeit | 4496 | 45,41% |
| | Summe von Anmeldungsdauer | 9900 | |
| 14:00 | Summe von Freie Zeit | 4129 | 38,53% |
| | Summe von Anmeldungsdauer | 10715 | |
| 14:15 | Summe von Freie Zeit | 5638 | 48,77% |
| | Summe von Anmeldungsdauer | 11560 | |
| 14:30 | Summe von Freie Zeit | 4580 | 37,54% |
| | Summe von Anmeldungsdauer | 12199 | |

| | | | |
|-------|---------------------------|-------|--------|
| 14:45 | Summe von Freie Zeit | 5820 | 47,99% |
| | Summe von Anmeldungsdauer | 12128 | |
| 15:00 | Summe von Freie Zeit | 4454 | 35,27% |
| | Summe von Anmeldungsdauer | 12630 | |
| 15:15 | Summe von Freie Zeit | 3958 | 36,65% |
| | Summe von Anmeldungsdauer | 10800 | |
| 15:30 | Summe von Freie Zeit | 2025 | 18,75% |
| | Summe von Anmeldungsdauer | 10800 | |
| 15:45 | Summe von Freie Zeit | 2912 | 28,58% |
| | Summe von Anmeldungsdauer | 10190 | |
| 16:00 | Summe von Freie Zeit | 1488 | 15,64% |
| | Summe von Anmeldungsdauer | 9512 | |
| 16:15 | Summe von Freie Zeit | 3914 | 37,14% |
| | Summe von Anmeldungsdauer | 10539 | |
| 16:30 | Summe von Freie Zeit | 4938 | 44,01% |
| | Summe von Anmeldungsdauer | 11221 | |
| 16:45 | Summe von Freie Zeit | 5683 | 48,18% |
| | Summe von Anmeldungsdauer | 11795 | |
| 17:00 | Summe von Freie Zeit | 4822 | 37,35% |
| | Summe von Anmeldungsdauer | 12911 | |
| 17:15 | Summe von Freie Zeit | 5215 | 38,63% |
| | Summe von Anmeldungsdauer | 13500 | |
| 17:30 | Summe von Freie Zeit | 6193 | 45,87% |
| | Summe von Anmeldungsdauer | 13500 | |
| 17:45 | Summe von Freie Zeit | 4637 | 36,16% |
| | Summe von Anmeldungsdauer | 12825 | |
| 18:00 | Summe von Freie Zeit | 5627 | 43,41% |
| | Summe von Anmeldungsdauer | 12962 | |
| 18:15 | Summe von Freie Zeit | 6216 | 47,72% |
| | Summe von Anmeldungsdauer | 13027 | |
| 18:30 | Summe von Freie Zeit | 5047 | 40,06% |
| | Summe von Anmeldungsdauer | 12600 | |
| 18:45 | Summe von Freie Zeit | 5656 | 45,57% |
| | Summe von Anmeldungsdauer | 12413 | |
| 19:00 | Summe von Freie Zeit | 3548 | 28,36% |
| | Summe von Anmeldungsdauer | 12512 | |
| 19:15 | Summe von Freie Zeit | 4918 | 39,03% |
| | Summe von Anmeldungsdauer | 12600 | |
| 19:30 | Summe von Freie Zeit | 4464 | 35,43% |
| | Summe von Anmeldungsdauer | 12600 | |
| 19:45 | Summe von Freie Zeit | 3482 | 29,29% |
| | Summe von Anmeldungsdauer | 11886 | |
| 20:00 | Summe von Freie Zeit | 4211 | 35,99% |
| | Summe von Anmeldungsdauer | 11700 | |
| 20:15 | Summe von Freie Zeit | 4456 | 38,09% |
| | Summe von Anmeldungsdauer | 11700 | |
| 20:30 | Summe von Freie Zeit | 4774 | 40,80% |
| | Summe von Anmeldungsdauer | 11700 | |
| 20:45 | Summe von Freie Zeit | 3691 | 32,53% |
| | Summe von Anmeldungsdauer | 11348 | |
| 21:00 | Summe von Freie Zeit | 5211 | 48,28% |
| | Summe von Anmeldungsdauer | 10794 | |

| | | | |
|-----------------------------------|---------------------------|--------|--------|
| 21:15 | Summe von Freie Zeit | 4460 | 55,06% |
| | Summe von Anmeldungsdauer | 8100 | |
| 21:30 | Summe von Freie Zeit | 4323 | 53,20% |
| | Summe von Anmeldungsdauer | 8126 | |
| 21:45 | Summe von Freie Zeit | 3607 | 50,10% |
| | Summe von Anmeldungsdauer | 7200 | |
| 22:00 | Summe von Freie Zeit | 5011 | 65,58% |
| | Summe von Anmeldungsdauer | 7641 | |
| 22:15 | Summe von Freie Zeit | 4428 | 64,23% |
| | Summe von Anmeldungsdauer | 6894 | |
| 22:30 | Summe von Freie Zeit | 4449 | 69,52% |
| | Summe von Anmeldungsdauer | 6400 | |
| 22:45 | Summe von Freie Zeit | 5117 | 70,94% |
| | Summe von Anmeldungsdauer | 7213 | |
| 23:00 | Summe von Freie Zeit | 5273 | 64,72% |
| | Summe von Anmeldungsdauer | 8148 | |
| 23:15 | Summe von Freie Zeit | 3884 | 71,93% |
| | Summe von Anmeldungsdauer | 5400 | |
| 23:30 | Summe von Freie Zeit | 3834 | 70,72% |
| | Summe von Anmeldungsdauer | 5421 | |
| 23:45 | Summe von Freie Zeit | 3223 | 71,62% |
| | Summe von Anmeldungsdauer | 4500 | |
| 00:00 | Summe von Freie Zeit | 3441 | 76,25% |
| | Summe von Anmeldungsdauer | 4513 | |
| Gesamt: Summe von Freie Zeit | | 327551 | |
| Gesamt: Summe von Anmeldungsdauer | | 713356 | 45,92% |

A4.3 Vergleich des Callaufkommens an Feiertagen mit dem an Wochenenden

Codierung: 1= Feiertag an einem Montag; 2= Feiertag an einem Dienstag; 3= Feiertag an einem Mittwoch; 4= Feiertag an einem Donnerstag; 5= Feiertag an einem Freitag; 6= Samstag; 7= Sonntag.

Es sei hier zudem angemerkt, dass die Fallzahlen bei den einzelnen Tests jeweils zu gering sind, als dass von einem validen Ergebnis sprechen zu können. Dennoch sollen die Tests als grundlegende Tendenz der Mittelwertvergleiche angesehen werden.

T-Test

Group Statistics

| | Intercept | N | Mean | Std. Deviation | Std. Error Mean |
|-------|-----------|----|-----------|----------------|-----------------|
| Total | 1 | 6 | 8091,1667 | 4719,81561 | 1926,857 |
| | 6 | 60 | 7449,1000 | 593,63068 | 76,63739 |

Independent Samples Test

| | | Levene's Test for Equality of Variances | | t-test for Equality of Means | | | | | | |
|-------|-----------------------------|---|------|------------------------------|-------|-----------------|-----------------|-----------------------|---|----------|
| | | F | Sig. | t | df | Sig. (2-tailed) | Mean Difference | Std. Error Difference | 95% Confidence Interval of the Difference | |
| | | | | | | | | | Lower | Upper |
| Total | Equal variances assumed | 229,835 | ,000 | 1,043 | 64 | ,301 | 642,06667 | 615,32558 | -587,187 | 1871,321 |
| | Equal variances not assumed | | | ,333 | 5,016 | ,753 | 642,06667 | 1928,3801 | -4310,29 | 5594,424 |

T-Test

Group Statistics

| | Intercept | N | Mean | Std. Deviation | Std. Error Mean |
|-------|-----------|----|-----------|----------------|-----------------|
| Total | 2 | 1 | 13691,00 | . | . |
| | 6 | 60 | 7449,1000 | 593,63068 | 76,63739 |

Independent Samples Test

| | | Levene's Test for Equality of Variances | | t-test for Equality of Means | | | | | 95% Confidence Interval of the Difference | |
|-------|-----------------------------|---|------|------------------------------|----|-----------------|-----------------|-----------------------|---|----------|
| | | F | Sig. | t | df | Sig. (2-tailed) | Mean Difference | Std. Error Difference | Lower | Upper |
| Total | Equal variances assumed | . | . | 10,428 | 59 | ,000 | 6241,9000 | 598,55716 | 5044,190 | 7439,610 |
| | Equal variances not assumed | | | | | | 6241,9000 | | | |

T-Test

Group Statistics

| | Intercept | N | Mean | Std. Deviation | Std. Error Mean |
|-------|-----------|----|-----------|----------------|-----------------|
| Total | 3 | 2 | 7585,5000 | 2191,32391 | 1549,500 |
| | 6 | 60 | 7449,1000 | 593,63068 | 76,63739 |

Independent Samples Test

| | | Levene's Test for Equality of Variances | | t-test for Equality of Means | | | | | 95% Confidence Interval of the Difference | |
|-------|-----------------------------|---|------|------------------------------|-------|-----------------|-----------------|-----------------------|---|----------|
| | | F | Sig. | t | df | Sig. (2-tailed) | Mean Difference | Std. Error Difference | Lower | Upper |
| Total | Equal variances assumed | 20,029 | ,000 | ,291 | 60 | ,772 | 136,40000 | 469,45409 | -802,648 | 1075,448 |
| | Equal variances not assumed | | | ,088 | 1,005 | ,944 | 136,40000 | 1551,3941 | -19350,3 | 19623,11 |

T-Test

Group Statistics

| | Intercept | N | Mean | Std. Deviation | Std. Error Mean |
|-------|-----------|----|-----------|----------------|-----------------|
| Total | 4 | 7 | 8051,8571 | 2916,78096 | 1102,440 |
| | 6 | 60 | 7449,1000 | 593,63068 | 76,63739 |

Independent Samples Test

| | | Levene's Test for Equality of Variances | | t-test for Equality of Means | | | | | 95% Confidence Interval of the Difference | |
|-------|-----------------------------|---|------|------------------------------|-------|-----------------|-----------------|-----------------------|---|----------|
| | | F | Sig. | t | df | Sig. (2-tailed) | Mean Difference | Std. Error Difference | Lower | Upper |
| Total | Equal variances assumed | 84,900 | ,000 | 1,436 | 65 | ,156 | 602,75714 | 419,88515 | -235,811 | 1441,326 |
| | Equal variances not assumed | | | ,545 | 6,058 | ,605 | 602,75714 | 1105,1001 | -2095,05 | 3300,564 |

T-Test

Group Statistics

| | Intercept | N | Mean | Std. Deviation | Std. Error Mean |
|-------|-----------|----|-----------|----------------|-----------------|
| Total | 5 | 5 | 7708,6000 | 3225,80677 | 1442,625 |
| | 6 | 60 | 7449,1000 | 593,63068 | 76,63739 |

Independent Samples Test

| | | Levene's Test for Equality of Variances | | t-test for Equality of Means | | | | | | |
|-------|-----------------------------|---|------|------------------------------|-------|-----------------|-----------------|-----------------------|---|----------|
| | | F | Sig. | t | df | Sig. (2-tailed) | Mean Difference | Std. Error Difference | 95% Confidence Interval of the Difference | |
| | | | | | | | | Lower | | Upper |
| Total | Equal variances assumed | 63,601 | ,000 | ,560 | 63 | ,577 | 259,50000 | 463,30761 | -666,346 | 1185,346 |
| | Equal variances not assumed | | | ,180 | 4,023 | ,866 | 259,50000 | 1444,6588 | -3742,64 | 4261,642 |

T-Test

Group Statistics

| | Intercept | N | Mean | Std. Deviation | Std. Error Mean |
|-------|-----------|----|-----------|----------------|-----------------|
| Total | 5 | 5 | 7708,6000 | 3225,80677 | 1442,625 |
| | 7 | 61 | 5621,3279 | 2256,75077 | 288,94733 |

Independent Samples Test

| | | Levene's Test for Equality of Variances | | t-test for Equality of Means | | | | | | |
|-------|-----------------------------|---|------|------------------------------|-------|-----------------|-----------------|-----------------------|---|----------|
| | | F | Sig. | t | df | Sig. (2-tailed) | Mean Difference | Std. Error Difference | 95% Confidence Interval of the Difference | |
| | | | | | | | | Lower | | Upper |
| Total | Equal variances assumed | 2,888 | ,094 | 1,926 | 64 | ,058 | 2087,2721 | 1083,4806 | -77,22921 | 4251,773 |
| | Equal variances not assumed | | | 1,419 | 4,327 | ,224 | 2087,2721 | 1471,2771 | -1878,76 | 6053,308 |

T-Test

Group Statistics

| | Intercept | N | Mean | Std. Deviation | Std. Error Mean |
|-------|-----------|----|-----------|----------------|-----------------|
| Total | 4 | 7 | 8051,8571 | 2916,78096 | 1102,440 |
| | 7 | 61 | 5621,3279 | 2256,75077 | 288,94733 |

Independent Samples Test

| | | Levene's Test for Equality of Variances | | t-test for Equality of Means | | | | | | |
|-------|-----------------------------|---|------|------------------------------|-------|-----------------|-----------------|-----------------------|---|----------|
| | | F | Sig. | t | df | Sig. (2-tailed) | Mean Difference | Std. Error Difference | 95% Confidence Interval of the Difference | |
| | | | | | | | | Lower | | Upper |
| Total | Equal variances assumed | 3,722 | ,058 | 2,620 | 66 | ,011 | 2430,5293 | 927,62421 | 578,46779 | 4282,591 |
| | Equal variances not assumed | | | 2,133 | 6,849 | ,071 | 2430,5293 | 1139,6770 | -276,435 | 5137,493 |

T-Test

Group Statistics

| | Intercept | N | Mean | Std. Deviation | Std. Error Mean |
|-------|-----------|----|-----------|----------------|-----------------|
| Total | 3 | 2 | 7585,5000 | 2191,32391 | 1549,500 |
| | 7 | 61 | 5621,3279 | 2256,75077 | 288,94733 |

Independent Samples Test

| | | Levene's Test for Equality of Variances | | t-test for Equality of Means | | | | | | | |
|-------|-----------------------------|---|------|------------------------------|-------|-----------------|-----------------|-----------------------|---|----------|-------|
| | | F | Sig. | t | df | Sig. (2-tailed) | Mean Difference | Std. Error Difference | 95% Confidence Interval of the Difference | | |
| | | | | | | | | | | Lower | Upper |
| Total | Equal variances assumed | ,236 | ,629 | 1,212 | 61 | ,230 | 1964,1721 | 1620,9531 | -1277,12 | 5205,468 | |
| | Equal variances not assumed | | | 1,246 | 1,071 | ,420 | 1964,1721 | 1576,2109 | -15192,2 | 19120,56 | |

T-Test

Group Statistics

| | Intercept | N | Mean | Std. Deviation | Std. Error Mean |
|-------|-----------|----|-----------|----------------|-----------------|
| Total | 2 | 1 | 13691,00 | . | . |
| | 7 | 61 | 5621,3279 | 2256,75077 | 288,94733 |

Independent Samples Test

| | | Levene's Test for Equality of Variances | | t-test for Equality of Means | | | | | | | |
|-------|-----------------------------|---|------|------------------------------|----|-----------------|-----------------|-----------------------|---|----------|-------|
| | | F | Sig. | t | df | Sig. (2-tailed) | Mean Difference | Std. Error Difference | 95% Confidence Interval of the Difference | | |
| | | | | | | | | | | Lower | Upper |
| Total | Equal variances assumed | . | . | 3,547 | 60 | ,001 | 8069,6721 | 2275,1735 | 3518,647 | 12620,70 | |
| | Equal variances not assumed | | | . | . | . | 8069,6721 | . | . | . | |

T-Test

Group Statistics

| | Intercept | N | Mean | Std. Deviation | Std. Error Mean |
|-------|-----------|----|-----------|----------------|-----------------|
| Total | 1 | 6 | 8091,1667 | 4719,81561 | 1926,857 |
| | 7 | 61 | 5621,3279 | 2256,75077 | 288,94733 |

Independent Samples Test

| | | Levene's Test for Equality of Variances | | t-test for Equality of Means | | | | | | | |
|-------|-----------------------------|---|------|------------------------------|-------|-----------------|-----------------|-----------------------|---|----------|-------|
| | | F | Sig. | t | df | Sig. (2-tailed) | Mean Difference | Std. Error Difference | 95% Confidence Interval of the Difference | | |
| | | | | | | | | | | Lower | Upper |
| Total | Equal variances assumed | 13,382 | ,001 | 2,279 | 65 | ,026 | 2469,8388 | 1083,6442 | 305,65184 | 4634,026 | |
| | Equal variances not assumed | | | 1,268 | 5,227 | ,258 | 2469,8388 | 1948,4012 | -2473,92 | 7413,593 | |

A5 Quellcode der Simulationsstudie

A5.1 Simulation für Montag

```
Sub simulation()  
'  
' simulation Makro  
'  
' Tastenkombination: Strg+s  
'  
Dim count As Integer  
Dim spalte As Integer  
count = 94  
Do  
ActiveSheet.Cells(count, 7).Select  
  
Selection.Copy  
Windows("G_G_cSim.xls").Activate  
Range("J6").Select  
ActiveSheet.Paste  
Windows("DissGammaGammaMontag.xls").Activate  
Cells(count, 8).Select  
  
Selection.Copy  
Windows("G_G_cSim.xls").Activate  
Range("K6").Select  
ActiveSheet.Paste  
Windows("DissGammaGammaMontag.xls").Activate  
Cells(count, 3).Select  
  
Selection.Copy  
Windows("G_G_cSim.xls").Activate  
Range("J8").Select  
ActiveSheet.Paste  
Windows("DissGammaGammaMontag.xls").Activate  
Cells(count, 4).Select  
  
Selection.Copy  
Windows("G_G_cSim.xls").Activate  
Range("K8").Select  
ActiveSheet.Paste  
For spalte = 12 To 60 Step 1  
  
Windows("DissGammaGammaMontag.xls").Activate  
Cells(2, spalte).Select  
  
Selection.Copy  
Windows("G_G_cSim.xls").Activate  
Range("I10").Select  
ActiveSheet.Paste  
Application.Run "G_G_cSim.xls!solveModel"
```

```

Range("I19:I26").Select
Selection.Copy
Windows("DissGammaGammaMontag.xls").Activate
Cells(count, spalte).Select

Selection.PasteSpecial Paste:=xlPasteValues, Operation:=xlNone, SkipBlanks _
:=False, Transpose:=False
Next spalte
count = count + 40
Loop While count < 177

```

End Sub

A5.2 Simulation für Dienstag bis Freitag

```

Sub Simulation()
'
' Simulation Makro
'
' Tastenkombination: Strg+s
'
Dim count As Integer
Dim spalte As Integer
count = 3
Do
Cells(count, 2).Select
Selection.Copy
Windows("G_G_cSim.xls").Activate
ActiveWindow.WindowState = xlNormal
ActiveWindow.WindowState = xlNormal
Range("J6").Select
ActiveSheet.Paste
Windows("DissGammaLNVDibisFr.xls").Activate
Cells(count, 3).Select
Selection.Copy
Windows("G_G_cSim.xls").Activate
ActiveWindow.WindowState = xlNormal
ActiveWindow.WindowState = xlNormal
Range("K6").Select
ActiveSheet.Paste
Windows("DissGammaLNVDibisFr.xls").Activate
Cells(count, 7).Select
Selection.Copy
Windows("G_G_cSim.xls").Activate
ActiveWindow.WindowState = xlNormal
ActiveWindow.WindowState = xlNormal
Range("J8").Select
ActiveSheet.Paste
Windows("DissGammaLNVDibisFr.xls").Activate
Cells(count, 8).Select
Selection.Copy
Windows("G_G_cSim.xls").Activate
ActiveWindow.WindowState = xlNormal

```

```
ActiveWindow.WindowState = xlNormal
Range("K8").Select
ActiveSheet.Paste
```

```
For spalte = 10 To 58 Step 1
```

```
Windows("DissGammaLNVDibisFr.xls").Activate
Cells(1, spalte).Select
Selection.Copy
Windows("G_G_cSim.xls").Activate
ActiveWindow.WindowState = xlNormal
ActiveWindow.WindowState = xlNormal
Range("I10").Select
ActiveSheet.Paste
Application.Run "G_G_cSim.xls!solveModel"
With ActiveWindow
    .Top = 69.25
    .Left = 112.75
End With
ActiveWindow.SmallScroll Down:=12
Range("I19:I26").Select
Selection.Copy
Windows("DissGammaLNVDibisFr.xls").Activate
Cells(count, spalte).Select
```

```
Selection.PasteSpecial Paste:=xlPasteValues, Operation:=xlNone, SkipBlanks _
:=False, Transpose:=False
```

```
Next spalte
count = count + 10
Loop While count < 235
```

```
End Sub
```

```
Sub Continue()
```

```
Dim count As Integer
Dim spalte As Integer
count = 233
Do
    Cells(count, 2).Select
    Selection.Copy
    Windows("G_G_cSim.xls").Activate
    ActiveWindow.WindowState = xlNormal
    ActiveWindow.WindowState = xlNormal
    Range("J6").Select
    ActiveSheet.Paste
    Windows("DissGammaLNVDibisFr.xls").Activate
    Cells(count, 3).Select
    Selection.Copy
    Windows("G_G_cSim.xls").Activate
    ActiveWindow.WindowState = xlNormal
    ActiveWindow.WindowState = xlNormal
```

```
Range("K6").Select
ActiveSheet.Paste
Windows("DissGammaLNVDibisFr.xls").Activate
Cells(count, 7).Select
Selection.Copy
Windows("G_G_cSim.xls").Activate
ActiveWindow.WindowState = xlNormal
ActiveWindow.WindowState = xlNormal
Range("J8").Select
ActiveSheet.Paste
Windows("DissGammaLNVDibisFr.xls").Activate
Cells(count, 8).Select
Selection.Copy
Windows("G_G_cSim.xls").Activate
ActiveWindow.WindowState = xlNormal
ActiveWindow.WindowState = xlNormal
Range("K8").Select
ActiveSheet.Paste
```

For spalte = 10 To 58 Step 1

```
Windows("DissGammaLNVDibisFr.xls").Activate
Cells(1, spalte).Select
Selection.Copy
Windows("G_G_cSim.xls").Activate
ActiveWindow.WindowState = xlNormal
ActiveWindow.WindowState = xlNormal
Range("I10").Select
ActiveSheet.Paste
Application.Run "G_G_cSim.xls!solveModel"
With ActiveWindow
    .Top = 69.25
    .Left = 112.75
End With
ActiveWindow.SmallScroll Down:=12
Range("I19:I26").Select
Selection.Copy
Windows("DissGammaLNVDibisFr.xls").Activate
Cells(count, spalte).Select
```

```
Selection.PasteSpecial Paste:=xlPasteValues, Operation:=xlNone, SkipBlanks _
:=False, Transpose:=False
```

```
Next spalte
count = count + 10
Loop While count < 235
```

End Sub

A5.3 Simulation für Samstag

```
Sub Simulation()
'
' Simulation Makro
'
'
' Tastenkombination: Strg+s
'
Dim count As Integer
Dim spalte As Integer
count = 3
Do
    Cells(count, 2).Select
    Selection.Copy
    Windows("G_G_cSim.xls").Activate
    ActiveWindow.WindowState = xlNormal
    ActiveWindow.WindowState = xlNormal
    Range("J6").Select
    ActiveSheet.Paste
    Windows("DissGammaGammaSamstag.xls").Activate
    Cells(count, 3).Select
    Selection.Copy
    Windows("G_G_cSim.xls").Activate
    ActiveWindow.WindowState = xlNormal
    ActiveWindow.WindowState = xlNormal
    Range("K6").Select
    ActiveSheet.Paste
    Windows("DissGammaGammaSamstag.xls").Activate
    Cells(count, 7).Select
    Selection.Copy
    Windows("G_G_cSim.xls").Activate
    ActiveWindow.WindowState = xlNormal
    ActiveWindow.WindowState = xlNormal
    Range("J8").Select
    ActiveSheet.Paste
    Windows("DissGammaGammaSamstag.xls").Activate
    Cells(count, 8).Select
    Selection.Copy
    Windows("G_G_cSim.xls").Activate
    ActiveWindow.WindowState = xlNormal
    ActiveWindow.WindowState = xlNormal
    Range("K8").Select
    ActiveSheet.Paste

    For spalte = 10 To 58 Step 1

        Windows("DissGammaGammaSamstag.xls").Activate
        Cells(1, spalte).Select
        Selection.Copy
        Windows("G_G_cSim.xls").Activate
        ActiveWindow.WindowState = xlNormal
        ActiveWindow.WindowState = xlNormal
```

```
Range("I10").Select
ActiveSheet.Paste
Application.Run "G_G_cSim.xls!solveModel"
With ActiveWindow
    .Top = 69.25
    .Left = 112.75
End With
ActiveWindow.SmallScroll Down:=12
Range("I19:I26").Select
Selection.Copy
Windows("DissGammaGammaSamstag.xls").Activate
Cells(count, spalte).Select

Selection.PasteSpecial Paste:=xlPasteValues, Operation:=xlNone, SkipBlanks _
    :=False, Transpose:=False

Next spalte
count = count + 10
Loop While count < 235

End Sub
```

```
Sub Continue()
```

```
Dim count As Integer
Dim spalte As Integer
count = 233
Do
    Cells(count, 2).Select
    Selection.Copy
    Windows("G_G_cSim.xls").Activate
    ActiveWindow.WindowState = xlNormal
    ActiveWindow.WindowState = xlNormal
    Range("J6").Select
    ActiveSheet.Paste
    Windows("DissGammaGammaSamstag.xls").Activate
    Cells(count, 3).Select
    Selection.Copy
    Windows("G_G_cSim.xls").Activate
    ActiveWindow.WindowState = xlNormal
    ActiveWindow.WindowState = xlNormal
    Range("K6").Select
    ActiveSheet.Paste
    Windows("DissGammaGammaSamstag.xls").Activate
    Cells(count, 7).Select
    Selection.Copy
    Windows("G_G_cSim.xls").Activate
    ActiveWindow.WindowState = xlNormal
    ActiveWindow.WindowState = xlNormal
    Range("J8").Select
    ActiveSheet.Paste
    Windows("DissGammaGammaSamstag.xls").Activate
    Cells(count, 8).Select
```

```

Selection.Copy
Windows("G_G_cSim.xls").Activate
ActiveWindow.WindowState = xlNormal
ActiveWindow.WindowState = xlNormal
Range("K8").Select
ActiveSheet.Paste

```

```

For spalte = 10 To 58 Step 1

```

```

Windows("DissGammaGammaSamstag.xls").Activate
Cells(1, spalte).Select
Selection.Copy
Windows("G_G_cSim.xls").Activate
ActiveWindow.WindowState = xlNormal
ActiveWindow.WindowState = xlNormal
Range("I10").Select
ActiveSheet.Paste
Application.Run "G_G_cSim.xls!solveModel"
With ActiveWindow
    .Top = 69.25
    .Left = 112.75
End With
ActiveWindow.SmallScroll Down:=12
Range("I19:I26").Select
Selection.Copy
Windows("DissGammaGammaSamstag.xls").Activate
Cells(count, spalte).Select

```

```

Selection.PasteSpecial Paste:=xlPasteValues, Operation:=xlNone, SkipBlanks _
:=False, Transpose:=False

```

```

Next spalte
count = count + 10
Loop While count < 235

```

```

End Sub

```

A5.4 Simulation für Sonntag

```

Sub Simulation()
'
' Simulation Makro
'
' Tastenkombination: Strg+s
'
Dim count As Integer
Dim spalte As Integer
count = 3
Do
Cells(count, 2).Select
Selection.Copy
Windows("G_G_cSim.xls").Activate

```

```
ActiveWindow.WindowState = xlNormal
ActiveWindow.WindowState = xlNormal
Range("J6").Select
ActiveSheet.Paste
Windows("DissGammaGammaSonntag.xls").Activate
Cells(count, 3).Select
Selection.Copy
Windows("G_G_cSim.xls").Activate
ActiveWindow.WindowState = xlNormal
ActiveWindow.WindowState = xlNormal
Range("K6").Select
ActiveSheet.Paste
Windows("DissGammaGammaSonntag.xls").Activate
Cells(count, 7).Select
Selection.Copy
Windows("G_G_cSim.xls").Activate
ActiveWindow.WindowState = xlNormal
ActiveWindow.WindowState = xlNormal
Range("J8").Select
ActiveSheet.Paste
Windows("DissGammaGammaSonntag.xls").Activate
Cells(count, 8).Select
Selection.Copy
Windows("G_G_cSim.xls").Activate
ActiveWindow.WindowState = xlNormal
ActiveWindow.WindowState = xlNormal
Range("K8").Select
ActiveSheet.Paste

For spalte = 10 To 58 Step 1

Windows("DissGammaGammaSonntag.xls").Activate
Cells(1, spalte).Select
Selection.Copy
Windows("G_G_cSim.xls").Activate
ActiveWindow.WindowState = xlNormal
ActiveWindow.WindowState = xlNormal
Range("I10").Select
ActiveSheet.Paste
Application.Run "G_G_cSim.xls!solveModel"
With ActiveWindow
    .Top = 69.25
    .Left = 112.75
End With
ActiveWindow.SmallScroll Down:=12
Range("I19:I26").Select
Selection.Copy
Windows("DissGammaGammaSonntag.xls").Activate
Cells(count, spalte).Select

Selection.PasteSpecial Paste:=xlPasteValues, Operation:=xlNone, SkipBlanks _
:=False, Transpose:=False

Next spalte
```

```
count = count + 10
Loop While count < 235
```

```
End Sub
```

```
Sub Continue()
```

```
Dim count As Integer
```

```
Dim spalte As Integer
```

```
count = 183
```

```
Do
```

```
Cells(count, 2).Select
```

```
Selection.Copy
```

```
Windows("G_G_cSim.xls").Activate
```

```
ActiveWindow.WindowState = xlNormal
```

```
ActiveWindow.WindowState = xlNormal
```

```
Range("J6").Select
```

```
ActiveSheet.Paste
```

```
Windows("DissGammaGammaSonntag.xls").Activate
```

```
Cells(count, 3).Select
```

```
Selection.Copy
```

```
Windows("G_G_cSim.xls").Activate
```

```
ActiveWindow.WindowState = xlNormal
```

```
ActiveWindow.WindowState = xlNormal
```

```
Range("K6").Select
```

```
ActiveSheet.Paste
```

```
Windows("DissGammaGammaSonntag.xls").Activate
```

```
Cells(count, 7).Select
```

```
Selection.Copy
```

```
Windows("G_G_cSim.xls").Activate
```

```
ActiveWindow.WindowState = xlNormal
```

```
ActiveWindow.WindowState = xlNormal
```

```
Range("J8").Select
```

```
ActiveSheet.Paste
```

```
Windows("DissGammaGammaSonntag.xls").Activate
```

```
Cells(count, 8).Select
```

```
Selection.Copy
```

```
Windows("G_G_cSim.xls").Activate
```

```
ActiveWindow.WindowState = xlNormal
```

```
ActiveWindow.WindowState = xlNormal
```

```
Range("K8").Select
```

```
ActiveSheet.Paste
```

```
For spalte = 10 To 58 Step 1
```

```
Windows("DissGammaGammaSonntag.xls").Activate
```

```
Cells(1, spalte).Select
```

```
Selection.Copy
```

```
Windows("G_G_cSim.xls").Activate
```

```
ActiveWindow.WindowState = xlNormal
```

```
ActiveWindow.WindowState = xlNormal
```

```
Range("I10").Select
```

```
ActiveSheet.Paste
```

```
Application.Run "G_G_cSim.xls!solveModel"  
With ActiveWindow  
    .Top = 69.25  
    .Left = 112.75  
End With  
ActiveWindow.SmallScroll Down:=12  
Range("I19:I26").Select  
Selection.Copy  
Windows("DissGammaGammaSonntag.xls").Activate  
Cells(count, spalte).Select  
  
Selection.PasteSpecial Paste:=xlPasteValues, Operation:=xlNone, SkipBlanks _  
    :=False, Transpose:=False  
  
Next spalte  
count = count + 10  
Loop While count < 188  
  
End Sub
```

Literaturverzeichnis:**Abe (1995),**

Abe, S. (1995): Neural Networks and Fuzzy Systems: Theory and Applications, 1. Aufl., Norwell, MA 1995.

Allen (1978),

Allen, A. O. (1978): Probability, Statistics, and Queuing Theorie With Computer Science Applications, 1. Aufl., New York et al. 1978.

Baccelli/Brémaud (1994),

Baccelli, F., Brémaud, P. (1994): Elements of Queueing Theory: Palm-Martingale calculus and stochastic recurrences, 1. Aufl., Berlin et al. 1994.

Bhat (1984),

Bhat, U.N. (1984): Elements of applied stochastic processes, 2. Aufl., New York et al. 1984.

Bodin/Dawson (2002),

Bodin, M., Dawson, K. (2002): Call Center Dictionary – The Complete Guide to Call Center & Customer Support Technology Solutions, 3. Aufl., New York 2002.

Böse/Flieger (1999),

Böse, B., Flieger, E. (1999): Call Center – Mittelpunkt der Kundenkommunikation: Planungsschritte und Entscheidungshilfen für das erfolgreiche Zusammenwirken von Mensch, Organisation, Technik, 1. Aufl., Braunschweig et al. 1999.

Bokranz (1985),

Bokranz, R. (1985): Personalbedarfsermittlung in Wartesystemen, 1. Aufl., München 1985.

Braun/Feulner/Malaka (1997),

Braun, H., Feulner, J., Malaka, R. (1997): Praktikum neuronale Netze, 1. korr. Nachdr., Berlin et al. 1997.

Braun (1997),

Braun, H. (1997): Neuronale Netze: Optimierung durch Lernen und Evolution, 1. Aufl., Berlin et al. 1997.

Brause (1995),

Brause, R. (1995): Neuronale Netze, 2., überarb. und erw. Aufl., Stuttgart 1995.

Cleveland/Mayben/Greff (1998),

Cleveland, B., Mayben, J., Greff, G. (1998): Call-Center-Management: Leitfaden für Aufbau, Organisation und Führung von Teleservicecentern, 1.Aufl., Wiesbaden 1998.

Domany/van Hemmen/Schulten (1991),

Domany, E., van Hemmen, J.L., Schulten, K. (1991): Physics of Neural Networks, 1. Aufl., Berlin et al., 1991.

Dorffner (1991),

Dorffner, G. (1991): Konnektionismus, 1. Aufl., Stuttgart 1991.

Fahrmeir/Hamerle (1996),

Fahrmeir, L., Hamerle, A. (1996): Mehrdimensionale Zufallsvariablen und Verteilungen, in: Multivariate statistische Verfahren, hrsg. v. L. Fahrmeir, A. Hamerle, G. Tutz, 2., überarb. Aufl., Berlin et al. 1996, S. 18-48.

Gnedenko/König (1983),

Gnedenko, B.W., König, D. (1983): Handbuch der Bedienungstheorie I, 1. Aufl., Berlin 1983.

Grael (1992),

Grael, A. (1992): Neuronale Netze: Grundlagen und mathematische Modellierung, 1. Aufl., Mannheim et al. 1992.

Gross/Harris (1985),

Gross, D., Harris, C.M. (1985): Fundamentals of queueing theory, 2. Aufl., New York 1985.

Gurney (1997),

Gurney, K. (1997): An introduction to neural networks, 1. Aufl., London 1997.

Hall (1991),

Hall, R.W. (1991): Queueing methods: for services and manufacturing, 1. Aufl., Englewood Cliffs, NJ 1991.

Hebb (1949),

Hebb, D. O. (1949): The organization of behaviour: A neurophysiological theory, New York 1949.

Hecht-Nielsen (1989),

Hecht-Nielsen, R. (1989): Neurocomputing, Reading, 1. Aufl., MA et al. 1989.

Helber/Stolletz (2004a),

Helber, S., Stolletz, R. (2004): Call Center Management in der Praxis Strukturen und Prozesse betriebswirtschaftlich optimieren, 1. Aufl., Heidelberg et al. 2004.

Helber/Stolletz (2004b),

Helber, S., Stolletz, R. (2004): Grundlagen und Probleme der Personalbedarfsermittlung in Inbound-Call Centern, in: ZfB Produktion von Dienstleistungen, Ergänzungsheft 1/2004, S. 67-88, Wiesbaden 2004.

Heuer (1997),

Heuer, J. (1997): Neuronale Netze in der Industrie: Einführung – Analyse – Einsatzmöglichkeiten, 1. Aufl., Wiesbaden 1997.

Hillier/Lieberman (1997),

Hillier, F.S., Lieberman, G.J. (1997): Operations Research: Einführung, 5. Aufl., München et al. 1997.

Hoffmann (1993),

Hoffmann, N. (1993): Kleines Handbuch neuronale Netze: anwendungsorientiertes Wissen zum Lernen und Nachschlagen, 1. Aufl., Braunschweig et al. 1993.

Karayiannis/Venetsanopoulos (1993),

Karayiannis, N.B., Venetsanopoulos, A.N. (1993): Artificial neural networks: learning algorithms, performance evaluation, and applications, 1. Aufl., Norwell 1993.

Kesting (2004),

Kesting, V. (2004): Das Call Center – Jahr 2003 – Rückblick und Ausblick, in: Branchenindex Call Center, CRM, IT/TK, Telesales und –service, Sonderheft 2004, S. 6-9, Wiesbaden 2004.

Kinnebrock (1994),

Kinnebrock, W. (1994): Neuronale Netze: Grundlagen, Anwendungen, Beispiele, 2., verb. Aufl., München et al. 1994.

Köhle (1990),

Köhle, M. (1990): Neurale Netze, 1. Aufl., Wien et al. 1990.

König/Stoyan (1976),

König, D., Stoyan, D. (1976): Methoden der Bedienungstheorie, 1. Aufl., Braunschweig 1976.

Kung (1993),

Kung, S.Y. (1993): Digital Neural Networks, 1. Aufl., Englewood Cliffs 1993.

Little (1961),

Little, J. D. C (1961): A Proof for the Queueing Formula: $L = \lambda W$, in: Operations Research, Band 9, 3. Aufl., S. 383-387, Oxford 1961.

McCulloch/Pitts (1943),

McCulloch, W., Pitts, W. (1943): A logical calculus of the ideas immanent in nervous activity, in: Bulletin of Mathematical Biophysics, Vol. 5, S. 115-133, Oxford 1943.

Menzler-Trott (1999),

Menzler-Trott, E. (1999): Call-Center-Management: ein Leitfaden für Unternehmen zum effizienten Kundendialog, 1. Aufl., München 1999.

Menzler-Trott/Hasenmaile (2000),

Menzler-Trott, E., Hasenmaile, C. (2000): Arbeitnehmer im Call-Center: Situation – Rechte – Gestaltungsmöglichkeiten, 1. Aufl., Frankfurt am Main 2000.

Michels (1999),

Michels, H. R. (1999): Praxistips Call Center-Outsourcing: Passives Telefonmarketing – die Bedienung von eingehenden Anrufen, in: Call Center Management, hrsg. v. E. Menzler-Trott, München 1999, S. 151 – 173.

Nauck/Klawonn/Kruse (1996),

Nauck, D., Klawonn, F., Kruse, R. (1996): Neuronale Netze und Fuzzy-Systeme, 2., überarb. und erw. Aufl., Braunschweig et al. 1996.

Poddig (1992),

Poddig, T. (1992): Künstliche Intelligenz und Entscheidungstheorie, 1. Aufl., Diss. Wiesbaden 1992.

Radtke (2001),

Radtke, B. (2001): Service und Effizienz mangelhaft, in: TeleTalk, 11/2001, S. 56-58, Hannover 2001.

Rigoll (1993),

Rigoll, G. (1993): Neuronale Netze, 1. Aufl., Renningen-Malmsheim 1993.

Rojas (1993),

Rojas, R. (1993): Theorie der neuronalen Netze: eine systematische Einführung, 1. Aufl., Berlin et al. 1993.

Rudolph (1998),

Rudolph, A. (1998): Prognoseverfahren in der Praxis, 1. Aufl., Heidelberg 1998.

Ruiz-Palá/Avila-Beloso (1967),

Ruiz-Palá, E., Avila-Beloso, K. (1967): Wartezeit und Warteschlange, 1. Aufl., Meisenheim am Glan 1967.

Rumelhart/McClelland (1986),

Rumelhart, D.E., McClelland, J.L. (1986): Parallel Distributed Processing: Explorations in the Microstructure of Cognition, Volume 1, Foundations, Cambridge, MA 1986.

Rumelhart/Hinton/Williams (1986),

Rumelhart, D.E., Hinton, G.E., Williams, R.J. (1986): Learning Internal Representations by Error Propagation, in: Parallel Distributed Processing: Explorations in the Microstructure of Cognition, Volume 1, Foundations, Cambridge, MA 1986, S. 318-362.

Rumelhart/Hinton/McClelland (1986),

Rumelhart, D.E., Hinton, G.E., McClelland, J.L. (1986): A General Framework for Parallel Distributed Processing, in: Parallel Distributed Processing: Explorations in the Microstructure of Cognition, Volume 1, Foundations, Cambridge, MA 1986, S. 45-76.

Schmalen (1992),

Schmalen, H. (1992): Kommunikationspolitik: Werbeplanung, 2., überarb. und erw. Aufl., Stuttgart et al. 1992.

Schwarze (1980),

Schwarze, J. (1980): Statistische Kenngrößen zur Ex-post-Beurteilung von Prognosen (Prognosefehler), in: Angewandte Prognoseverfahren, hrsg. v. J. Schwarze, 1. Aufl., Herne et. al. 1980, S. 317-344.

Thieme/Steffen (1999),

Thieme, K.H., Steffen, W. (1999): Call Center – der professionelle Dialog mit dem Kunden: Aufbau – Management – Erfolgskontrolle, 1. Aufl., Landsberg/Lech 1999.

Wiencke/Koke (1999),

Wiencke, W., Koke, D. (1999): Call Center Praxis Den telefonischen Kundenservice erfolgreich organisieren, 2., überarb. und erw. Aufl., Stuttgart 1999.

Zell (2000),

Zell, A. (2000): Simulation neuronaler Netze, 3. unv. Nachdr., Bonn et al. 2000.

Zimmerer (1997),

Zimmerer, T. (1997): Künstliche neuronale Netze versus ökonometrische und zeitreihenanalytische Verfahren zur Prognose ökonomischer Zeitreihen, 1. Aufl., Diss. Frankfurt am Main et al., 1997.

Software:

BestFit,

BestFit 4.5, Palisade Corporation, 31 Decker Road, Newfield, NY USA 14867.

Clementine,

Clementine 8.5, SPSS Inc., 233 South Wacker Drive, Chicago, IL 60606-6412.