

Oberseminarvortrag

von

SimoneBeck

am22.05

Thema:

Erstellung eines Prognosemodells für die Fernsehnutzung
mit Hilfe Neuronaler Netze

1 Einleitung

In den letzten 15 Jahren hat das stetig wachsende Angebot privater Fernsehsender, die ebenfalls stetig zunehmende Anzahl mit Kabelanschluss versehener Haushalte und das reichhaltige Angebot an kommerziellen Satellitenprogrammen zu einer stark wachsenden Zahl von empfangbaren Fernsehprogrammen geführt. Im Gleichschritt damit wächst der Informationsbedarf über diejenigen Personen und Haushalte, für die diese Programme gemacht werden – als die Fernseh Zuschauer. Programmplaner, die an diesem Wettbewerb beteiligt sind, müssen daher immer mehr dafür sorgen, gute, schnelle und vergleichbare Informationen über die Reaktionen des Publikums zu erhalten.

Die Daten, die zur Vorhersage von Einschaltquoten benötigt werden, sind sehr komplex, da nicht nur die Charakteristika der Sendung selbst, sondern auch z. B. die der parallel und vorhergehenden Sendungen Einfluss haben.

Um den Entscheidungsprozess, welche Sendung zu welcher Zeit bei einer möglichst großen Zuschauergruppe am besten ankommt, zu unterstützen, ist es das Ziel dieses Projektes, die zeitlich eingesetzten Methoden durch den Einsatz von Neuronalen Netzen zur Erstellung eines Prognosemodells zu ergänzen.

Die Software, mit deren Hilfe für die Prognose der Fernsehnutzungsdaten bestmögliches Neuronales Netz ermittelt werden soll, ist der SAS Enterprise Miner (Version 3.01). Dies ist die SAS – Lösung für Data Mining Prozesse, die die Realisierung einer kompletten Business – Lösung für Data Mining Fragestellungen ermöglicht.

Als eines der wenigen Softwarewerkzeuge beinhaltet der SAS Enterprise Miner dabei alle modernen Data Mining – Methoden wie Cluster –, Assoziations – und Regressionsanalyse, Entscheidungsbäume und Neuronale Netze. Benutzerfreundliche Visualisierungswerkzeuge erlauben die Auswertung großer Datenvolumen in multidimensionalen Histogrammen sowie den graphischen Vergleich der Ergebnisse der unterschiedlichen Modellierungsverfahren.

Aus der Vielzahl der Möglichkeiten, die der SAS Enterprise Miner in jedem Schritt des Data Mining Prozesses zur Verfügung stellt, ist es das Ziel dieser Arbeit, zu ermitteln, die bestmögliche Auswahl und Kombination für ein auf einem Neuronales Netz basierendes Prognosemodell zu finden und zum anderen Vorgehensweisen zu untersuchen, die versuchen, ein möglichst schnelles Ermitteln eines ausreichend guten Neuronales Netzmodell sicherzustellen.

2 Das biologische Vorbild [BAY1989, S.204 -216]

Das menschliche Gehirn ist eine der kompliziertesten Strukturen, die uns bekannt ist. Umso beachtenswerter ist, dass im Gehirn nur ein Grundtypus von Zelle existiert, der Informationen überträgt und diese in gewisser Weise auch speichern kann. Dieser Grundtypus wird mit Neuron oder Neuron bezeichnet.

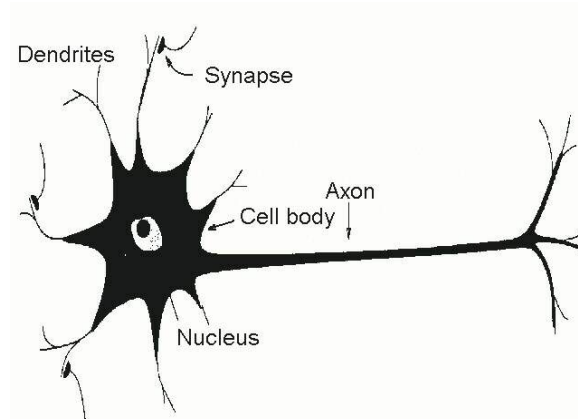


Abb.1: Schematische Nervenzelle des Menschen

Jedes Neuron besteht aus einem Zellkörper und mehreren Fortsätzen verschiedener Form und Länge, die aus diesem hervorgehen. Bis auf feinen werden diese Fortsätze Dendriten genannt, welche in der Regel kurz ($10 - 100 \mu\text{m}$) und stark verzweigt sind und dem Empfangen von Signalen anderer Neuronen dienen. Der sich von den Dendriten unterscheidende Fortsatz wird Neuronenfaser, Neurit oder Axon genannt und kann beim Menschen zwischen $10 \mu\text{m}$ und 1m lang sein. Auch das Axon ist verzweigt, aber im Gegensatz zu den Dendriten sind die Enden eines Axons sackartig erweitert. Diese Verdickungen legen sich an den Zellkörper, die Dendriten eines anderen Neurons oder auch an eine Muskelfaser an und bilden so eine Synapse. Wird ein Neuron erregt, so dient das Axon der Weiterleitung dieses Signals zu den Synapsen, die die Erregung von einer Zelle auf die andere übertragen. Diese Weiterleitung, Aufnahme und Verarbeitung von Informationen in Neuronen erfolgt über Spannungsänderungen, welche durch positiv und negativ geladene Ionen zustandekommen, die je nach Erregung des Neurons durch dessen Membranporendiffundieren. Zwischen dem Inneren einer Zelle und der sie umspülenden Zwischenzellflüssigkeit, dem Außenmedium, besteht also eine von der Erregung des Neurons abhängige elektrische Spannung, die auch als Membranpotenzial bezeichnet wird. Sobald das Potenzial am Axonursprung einen bestimmten Schwellenwert überschreitet, entsteht dort ein sogenanntes Aktionspotenzial. Dieses pflanzt sich rasch bis zum Ende des Axons fort und sorgt an den Synapsen wiederum für die Freisetzung von Neurotransmittern. Wird der Schwellenwert nicht erreicht, so bleibt das Neuron vollkommen ruhig.

Technisch gesehen arbeitet also ein Neuron sehr einfach. Ankommende Signale mehrerer Zellen werden summiert und ab einem bestimmten Schwellenwert wird ein neues Signal an nachfolgende Neuronen weitergegeben. Dabei stellt sich jedoch die Frage, wo die Information selbst nun eigentlich zu finden ist. Da die Nervenzelle hauptsächlich der Signalübertragung dient und nur die Information des jeweils aktuellen Erregungszustandes speichern kann, muss dieser zusammen mit der Stärke der synaptischen Verbindung und der Topologie des Gehirns selbst das sein, was die Information enthält. Für Details siehe [COH1985], [ECC1977] und [THO1990].

Der mathematische Modellansatz, ein Neuron als einen Summierverstärker mit individueller Gewichtung seiner Eingänge zu verstehen, ist daher als durchaus naheliegend. Es muß jedoch klar sein, dass ein neuronales Netz zum mindesten mit heutigen Rechenleistungen kein vollkommene Abbild des Gehirns sein kann, da es sich zu einem nicht mit der Anzahl von ungefähr 10^{11} Neuronen und ca. 10^{14} Synapsen im menschlichen Hirn messen kann, die in hohem Maße parallel arbeiten, und da es zum andern nur rechnerische Prinzipien verwendet, die ausschließlich mit einfachen Abläufen in organischen Nervensystemen vergleichbar sind.

3 Grundlagen Neuronaler Netze

Dies ist ein allgemeingültiges Rahmenmodell künstlicher neuronaler Netze, die ein feedforward-Netz bestehen, wesentliche aus zwei Arten von Elementen, den Neuronen (auch Units oder Knoten genannt) und den Verbindungen zwischen den einzelnen Neuronen.

Jedes Neuron j mit $j \in \mathbb{N}$ besitzt eine Zustandsvariable $a_j(t)$, die den Zustand des Neurons j für einen Datensatz ausdrückt und deren Wert durch den Eingabewert $x_j(t)$ in das Neuron definiert wird. Auf die biologischen Neuronen übertragen, steht die Zustandsvariable $a_j(t)$ für das Potential am Axonursprung, das heißt für die elektrische Spannung innerhalb einer Nervenzelle zu einem bestimmten Zeitpunkt, weswegen sie auch Aktivierungszustand genannt wird.

Die in jedem künstlichen Neuron vorhandene Aktivierungsfunktion $A_j(a_j(t))$ bestimmt nun in

Abhängigkeit des aktuellen Zustands $a_j(t)$ den neuen Aktivierungszustand $a_j^*(t)$ des Neurons.

Um das für die Interaktion mit den übrigen Neuronen benötigte Ausgabe signal eines Neurons zu bestimmen, hat jedes Neuron neben der Aktivierungsfunktion auch eine Ausgabefunktion

$O_j(a_j^*(t))$, die durch die Aktivierungsfunktion erzeugten Zustand $a_j^*(t)$ auf das Ausgangs-

signal $o_j(t)$ abbildet. Dies ist wiederum analog zu den biologischen Neuronen, bei denen die

Signalstärke ebenfalls vom gerade aktuellen Zustand der Zelle abhängt.

Die eben schon angesprochene Interaktion aller Neuronen einschließend Verarbeitungsmenge U , geschieht in einem künstlichen neuronalen Netz mit Hilfe gewichteter Verbindungen,

die durch die Gewichtmenge W beschrieben werden. Ein Gewicht $w_{ij} \in W$ der Verbindung zwischen einem Neuron i und einem Neuron j bestimmt dabei zumeist die Stärke der Verbindung $|w_{ij}|$ (die Stärke der Verbindung, d.h. das Ausmaß, in dem die Aktivität a_i des Neurons i von der Aktivität a_j des Neurons j abhängt, und zum anderen legt das Vorzeichen des Gewichts w_{ij} fest, ob es sich um eine inhibitorische Verbindung (positives Gewicht) oder um eine excitatorische Verbindung (negatives Gewicht) handelt.

Aus Gründen der besseren Verständlichkeit wird an dieser Stelle für jedes Neuron j eine Teilmenge $W_j \subset W$ der Gewichtmenge eingeführt, in der alle Gewichte $w_{ij} \in W$ vereinigt sind, die zum Nettoinput $x_j(t)$ des Neurons j beitragen. Es gilt somit:

$$(Gl.1) \quad W_i \cap W_j = \emptyset \text{ und } \bigcup_{n=1}^N W_n = W$$

mit N = Anzahl aller Neuronen im Netz, die ihre Eingabe von anderen Neuronen im Netz beziehen.

Um den Nettoinput $x_j(t)$ für eine Unit j zu ermitteln, die mit einigen Units i in Verbindung steht, wird eine Nettoinputfunktion $C_j(W_j, \vec{o}(t))$ (auch Combination Function genannt) definiert,

die die Output $o_i(t)$ der Units i und die dazugehörigen Gewichte der Gewichtmenge W_j mit dem Input der Unit j in der Regelauffolgende Weise in Verbindung setzt:

$$(Gl.2) \quad C_j(W_j, \vec{o}(t)) = \sum_I w_{ij} o_i(t) = e_j(t)$$

mit $w_{ij} \in W_j, i, j \in \mathbb{N}, I = \text{Anz. der Units } i$

Die in eine Unit j eingehenden gewichteten Signale werden als meist additiv zusammengefasst.

Insgesamt kann man die Abläufe in einem einzelnen Neuron wie auch Abb. 2 zeigt, vereinfacht so beschreiben, dass es durch die Nettoinputfunktion $e_j(t)$ bestimmter Eingangswert den Aktivierungszustand $a_j(t)$ eines Neurons bestimmt, der durch die Aktivierungsfunktion

$A_j(a_j(t)) = a_j^*(t)$ modelliert und mit Hilfe der Ausgangsfunktion $O_j(a_j^*(t))$ auf das Ausgangssignal $o_j(t)$ abgebildet wird, welches über gewichtete Verbindungen mit anderen Neuronen interagiert, sofern es sich beim Neuron nicht um einen Netzausgang handelt, dem eine externe Ausgangssignal produziert.

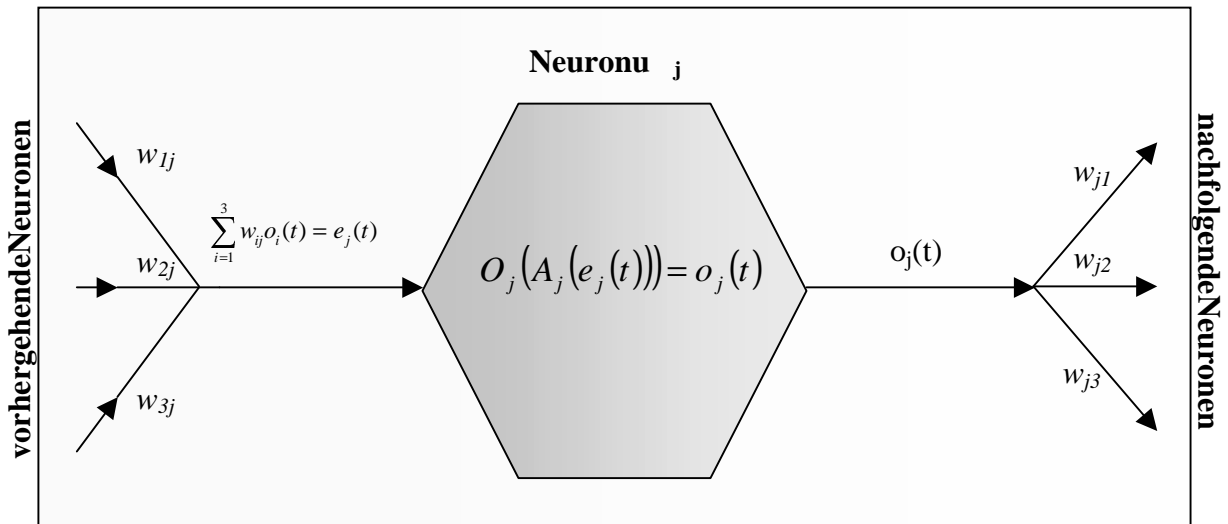


Abb.2: Abläufe im Neuron j mit 3 vorhergehenden und 3 nachfolgenden Neuronen

Künstliche Neuronen sind also letztlich gleichzusetzen mit primitiven Funktionen, die einen Eingabewert in einen Ausgabewert transformieren und das künstliche Neuronale Netzwerk aus miteinander verbundenen Neuronen besteht, hängen die Eigenschaften eines solchen neuronalen Netzes zu einem von den in den Neuronen verwendeten Funktionen und zu anderen von der Anordnung der Neuronen bzw. ihrer Verbindungsstruktur, d.h. von der Netztopologie ab, welche im nächsten Abschnitt was genauer betrachtet werden soll.

4 Netzaufbau

Indem in dieser Arbeit vorrangig betrachtet werden und für hierarchisch organisierte Netzwerke alle meingültigen Multilayer Feedforward Netze, werden die Neuronen in drei verschiedenen Arten von Schichten angeordnet, von denen zwei die Schnittstellen zur Umwelt darstellen. Dies sind die Input-Schicht, bestehend aus sogenannten Input-Neuronen, welche externe Eingabewerte erhalten, und die Output-Schicht, bestehend aus Output-Neuronen, die zwar ihre Eingabewerte vom Netz bekommen, aber externe Ausgabewerte, d.h. Werte, die nicht mehr an das Netz zurückfließen, produzieren.

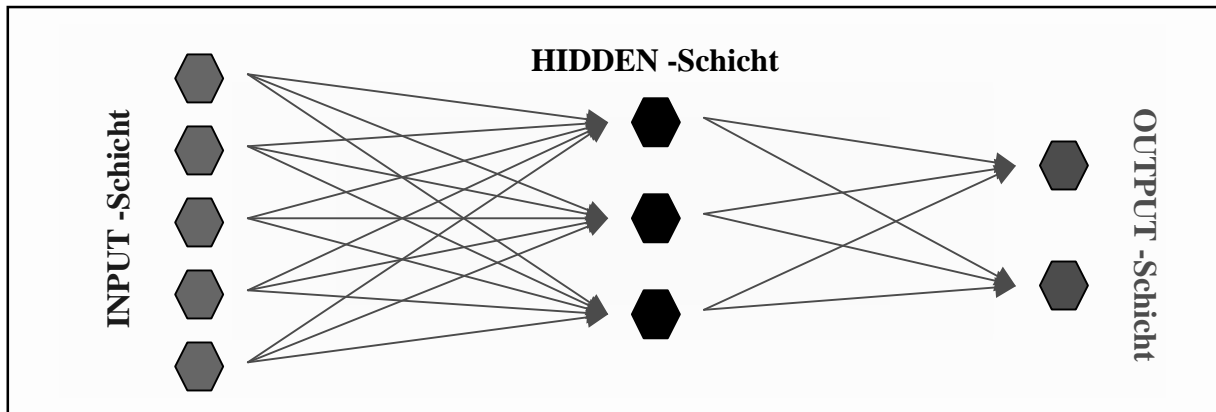


Abb.3: Hierarchische Grundstruktur eines Multilayerfeedforward -Netzes

WährendesineinemkünstlichenNeuronalenNetzzimmernurgenaueineInput -undgenaueine Output -SchichtmitjeweilseinbisendlichenvielenNeuronengibt,kannesvonderdritten ArtvonSchicht,derzwischen derInput -undOutput -SchichtliegendenHidden -Schicht keineoderendlichevielegeben.DiedieseSchichtbildendenHidden -Neuronenstellenden TeileinesNeuronalenNetzesdar,derinindieThematikeinführenderLiteraturoftalsblack boxbezeichnetwird, dadieseNeuronenkeineSchnittstellezurUmweltaufweisen,sondernnur mitanderenNeuroneninnerhalbdesNetzesinteragieren.

EinweitererfürdieEigenschafteneineskünstlichenNeuronalenNetzeswichtigerGesichtspunktistdieArtundWeisenauchwelcherStrukturdieNeuronenmiteinanderverbunden sind. AbgesehenvoneinemspeziellenFall,demselbstorganisierendenNeuronalenNetz,giltal gemeinen,dassNeuroneneinerSchichtuntereinanderkeineVerbindungenaufweisen,d.h.die NeuroneneinerSchichtinteragierennurmitNeuronenandererSchichten.DabeihabendieNeuroneneinerSchichtinderRegelnurVerbindungenzurvor-undnachgelagertenSchicht.Mö glich sind aber auch sogenannte lineare Konnektoren, die z. B. in einem dreischichtigen Multilayer Perceptron die Neuronen der Input -Schicht direkt mit den der Output -Schicht verbinden.

5 Netzfunktion

WieindenletztenbeidenAbschnittenüberdieVerarbeitungselementeunddenNetzaufbau beschrieben wurde, handelt es sich bei einem künstlichen Neuronalen Netz um ein Netz von Funktionen. Somit ist für jedes Netz dieser Art eine Netzfunktion definierbar, die unter Angabe des Eingabevektors und der einzelnen Gewichtsvektoren der Verbindungen den Ausgabevektor des Netzes berechnet.

Der Wert des Ausgabevektors eines Neuronalen Netzes hängt jedoch von einer Vielzahl von Faktoren ab. Diese sind neben der generellen Wahl der Netzstruktur,

- die Anzahl der im Netz vorhandenen Neuronen,
- die drei für den Ausgabewert eines einzelnen Neurons wichtigen Funktionen:
 - o die Nettoinputfunktion,
 - o die Aktivierungsfunktion,
 - o und die Ausgangsfunktion
- der Eingabevektor
- der Gewichtsvektor

Während die Netzstruktur, die Anzahl der Neuronen und die für sie gewählten Funktionen beim Training eines Netzmodells fest bleiben, ändert sich der Eingabevektor $\vec{e}(t)$ abhängig von der Zeit, da das Netz durchih nalle externen Datenmuster erhält, das heißt die gesamte externe Eingabematrix Schritt für Schritt an das Netz übergeben wird. Die zweite variable Größe ist der Gewichtsvektor \vec{w} der im Laufe der Trainingsphase eines Neuronalen Netzmodells bei jeder Iteration optimiert wird. Dieses Anpassen der einzelnen Gewichte aufgrund des Vergleichs von prognostizierten und historischen Werten stellt den eigentlichen Lernprozess innerhalb eines Neuronalen Netzes dar.

6 Der Lernprozess

Die Fähigkeit zu lernen ist eine der interessantesten Eigenschaften Neuronaler Netze. Im Fall der Funktionsapproximation, den wir hier betrachten, bedeutet das Lernen das Anpassen des Netzes, sodass es die Funktion $f: \mathbb{R}^d \rightarrow \mathbb{R}^c$, die sich in den Trainingsdaten widerspiegelt, möglichst gut repräsentiert und gleichzeitig auch für im Trainingsprozess noch unbekannte Testdaten gute Ausgabewerte errechnet. Dies kann nach A. Zell [ZEL 2000, S. 84] auf sieben unterschiedliche Arten erfolgen, die einzeln oder in Kombination angewendet werden können. Dazu zählen:

- Entwicklung neuer Verbindungen
- Löschen existierender Verbindungen
- Modifikation der Stärken w_{ij} von Verbindungen
- Modifikation des Schwellenwertes von Neuronen
- Modifikation der Aktivierungs-, Kombinations- oder Ausgabefunktion
- Entwicklung neuer Zellen
- Löschen von Zellen

Dabei befassen sich die ersten vier Alternativen mit der bestmöglichen Einstellung der Gewichte, die drei übrigen Alternativen mit der Optimierung der Netztopologie. Die mit Abstand am häufigsten verwendete Art des Lernens ist die Modifikation der Stärken w_{ij} der Verbindungen. Zuerst bei einem vollständig verbundenen Netz auch die ersten beiden Alternativen gezählt werden können, da dann zur Entwicklung einer neuen Verbindung das Verbindungsgewicht w_{ij} von Null in ein von Null verschiedenes Wert zugewiesen bekommen muss und das Löschen einer Verbindung in einem Verbindungsgewicht w_{ij} von Null entspricht. Auch die Modifikation des Schwellenwertes kann gemeinsam mit der dritten Alternative realisiert werden, das bei Vorhandensein eines separaten Bias-Neurons gleich der Modifikation von Gewichten behandelt wird.

7 Lernverfahren

Man unterscheidet im Allgemeinen in folgende Arten des Lernens in Neuronalen Netzen [HEI 1997, S. 17ff]:

- Überwachtes Lernen: Hier liegt dem Netz zu jedem Eingabemuster der Trainingsdaten das korrekte Ausgabemuster vor und es ist somit die Aufgabe des Lernverfahrens, das Netz so anzupassen, dass es für unbekannte, ähnliche Eingabemuster beste Ausgabemuster berechnen kann.
- Bestärkendes Lernen: Das Netz erhält hier lediglich bewertende Rückmeldungen über sein Verhalten, allerdings oft nur für Kombinationen von Entscheidungen und nicht für einzelne, was die Optimierung erschwert.
- Unüberwachtes Lernen: Hier stehen dem Netz Beobachtungen zur Verfügung, in denen es selbständig Eigenschaften über deren Struktur oder Verteilung, die ihm vorher nicht bekannt sind, erkennen soll.

8 Daten

Die Ergebnisse einer Prognose nicht nur von der Struktur und dem Aufbau des Prognosemodells, sondern auch von der Art, der Relevanz und der Güte der Informationen, die verarbeitet werden, abhängen, ist es vor einer statistischen Identifikation eines Prognosemodells erforderlich, mögliche Determinanten der vorherzusagenden Größe, hier der Fernsehnutzung, zu erörtern.

Bei der Auflistung der möglichen Determinanten der Fernsehnutzung kann man unterscheiden zwischen:

<u>strukturellen</u> ← (wiez. B. der Zuschauererreichbarkeit) →	<u>individuellen</u> (wiez. B. der Ausstattung eines Haushalts mit Fernsehtechnik)
<u>einfachen</u> ← (wiez. B. der Sendezeit)	<u>komplexen</u> (wiez. B. den Bedürfnissen der Zuschauer)
<u>prognostisch relevanten</u> ← (wiez. B. dem Programmangebot)	<u>prognostisch irrelevanten</u> (wiez. B. dem Wetter)

Da sich diese Arbeit mit der Konzeption eines Prognosemodells beschäftigt, bietet sich die Unterscheidung zwischen prognostisch relevanten und irrelevanten Determinanten an. Dabei ist eine Determinante prognostisch relevant, wenn sie zum Zeitpunkt der Prognoseberechnung bereits bekannt bzw. gut schätzbar ist und irrelevant, wenn sie (zu diesem Zeitpunkt) noch unbekannt oder nur schwer vorherhersagbar ist.

8.1 Prognostisch relevante Determinanten

Die prognostisch relevanten Determinanten können wieder in zwei Gruppen unterteilt werden. Die sind auf der einen Seite die Zuschauerbezogenen Determinanten, die die Zuschauerin bestimmte Zielgruppen einordnen können und Informationen über ihre Fernsehgewohnheiten beinhalten, und auf der anderen Seite die das Programm in Bezug auf Sendezeit, Platzierung, Genre und Attraktivität näher beschreibenden programmbezogenen Determinanten.

8.2 Prognostisch irrelevanten Determinanten

Zu einer die Fernsehnutzung zu einem Teil weise durchaus stark beeinflussenden Größe, die sich im Voraus jedoch nur für kurze Zeiträume und dies auch nicht immer genau abschätzen lässt, zählt an erster Stelle das Wetter. Hier kann nur dies über das gesamte Jahr erstreckende Wirkung der Jahreszeiten mit in das Prognosemodell einbezogen werden. Ebenfalls dem Modell zugänglich, wenn auch durchaus die Nutzung in erheblichem Maße beeinflussende Daten, sind Informationen über die persönliche Situation der Zuschauer. So sind die dem Zuschauer zur Verfügung stehende Freizeit, die Rezeptionssituation, d. h. die Zusammensetzung der Zuschauer vor einem Fernsehgerät und auch die individuelle Befindlichkeit und Stimmungslage der einzelnen Zuschauer auf keine Weise vorherhersagbar und daher prognostisch irrelevant.

9 Modellidentifikation

Der gesamte Prozess von der Datengewinnung bis zur vollständigen Konfiguration eines Neuronalen Netzes lässt sich im Wesentlichen gliedern in 3 Phasen. Die Aufbereitung der Daten wird gefolgt von der Spezifikation eines Basismodells und schließlich der Optimierung dieses sogenannten Basismodells, welches meist mit Hilfe der Standard-Einstellungen konfiguriert ist.

9.1 Vorbereitende Phase

Die eigentlich nur vorbereitende erste Phase besteht wiederum aus mehreren Schritten. Ausgehend von der Menge der Rohdaten wird in der Regel zur besseren Handhabung eine Stichprobe gezogen, da es der Zeitaufwand und die Rechnerkapazitäten nur selten zulassen, alle zur Verfügung stehenden Rohdaten in die Modellierung miteinzubeziehen. Die Daten der Stichprobe werden dann, um eine Optimierung mittels Kreuzvalidierung zu ermöglichen, in drei Datensätze Training, Validierung und Test aufgeteilt. Der letzte Schritt der vorbereitenden Phase besteht nun aus den für die Eingangsdaten eines Neuronalen Netzes notwendigen Transformationen, die eine einheitliche Skalierung und dem Filtern von Ausreißern und fehlenden Werten auch für eine günstige Verteilung der Prognosevariablen sorgen.

9.2 Spezifikationsphase

Die Spezifikationsphase, die sich im Grunde eigentlichen Konfiguration des Neuronalen Netzes befasst, läuft im SAS Enterprise Miner vollständig in der Komponente des Neuronalen Netzes ab. Da die Anzahl unterschiedlicher Konfigurationsmöglichkeiten sehr groß ist, was zur strukturierten Vorgehensweise bei der Modellidentifikation notwendig, eine entsprechende Methode zu entwickeln, um miteinander vergleichbare Modelle zu erhalten, anhand derer man Auswirkungen leicht modifizierter Parametrisierungen erkennen und für weitere Berechnung verwenden kann. Diese im Laufe der Zeit entwickelte Methode sieht vor, in einem ersten Schritt dem größten Teil der Parameter ein sich aus der Theorie und den verwendeten Daten ergäbendes und plausibles festes Wert zuzuweisen, der während der Optimierungsphase nur in Ausnahmefällen zu modifizieren ist. Die Anzahl der Variablenparameter sollte je nach der zur Verfügung stehenden Rechnerkapazität und dem geplanten Zeitaufwand gewählt werden, wobei zu beachten ist, dass ein 400 MHz PC mit 128 MB RAM bei 6000 Trainingsdatensätzen und je 4500 Validierungs- bzw. Testdatensätzen für ein Modell eine durchschnittliche Rechenzeit von ca. 30 Minuten benötigt.

Um eine eventuell automatisierte Vorgehensweise bei der Berechnung einer größeren Anzahl von Modellen zu ermöglichen, ist es in einem zweiten Schritt sinnvoll, eine Reihenfolge festzulegen, in der die Variablenparameter nach und nach variiert werden. Handelt es sich bei einem Variablenparameter um eine Intervallvariable wie z. B. die Anzahl der versteckten (bzw. hidden) Neuronen, bei der das Spektrum möglicher Werte höchstens durch die Rechenleistung des PCs beschränkt wird, so schlägt die Methode vor, einigemögliche Werte unterschiedlicher Größenordnung zu wählen, um damit in einem ersten Durchgang alle in einem weiteren Parameter wie z. B. dem Lernalgorithmus modifizierten Modelle zu berechnen. Dies hat den Vorteil, dass die Ergebnisse der zahlreichen zu berechnenden Modelle gut miteinander zu vergleichen sind und man auf schnelle Art und Weise einen ersten Überblick über die Entwicklung in unterschiedlichen Größenordnungen des Parameters erhält.

Die Auswertung der Ergebnisse dieser ersten Reihe von Modellberechnungen bilden im Folgenden die Grundlage, auf Basis derer der Anwender entscheiden muss, in welchem Bereich eine detailliertere Konfiguration vorzunehmen sollte, um dem Ziele eines möglichst optimalen Neuronalen Netzmodells näherzukommen.

Zusammengefasst besteht die Verfahrensweise aus folgenden vier Schritten:

- Klassifizierung der Parameter in feste und freie.
- Festlegung der Reihenfolge für die Variation der freien Parameter.
- Bei freien Parametern mit einem großen Spektrum an möglichen Werten: Festlegung einigervorübergehend konstanter Werte unterschiedlicher Größenordnung.
- Erstes Auswerten der Ergebnisse und darauf basierend detailliertere Konfigurationen vieler versprechender Modelltypen.

Um zusätzlich zur strukturierten Vorgehensweise den Überblick über die Vielzahl unterschiedlicher Modellkonfigurationen und Parameter zu erleichtern und damit gezielt detailliertere Untersuchungen erstichtig zu ermöglichen, wurde weiterhinein eine nach den einzelnen Bereichen eines neuronalen Netzes geordnete tabellarische Übersicht über die einzelnen Parameter und ihre möglichen Werte erstellt, in die die jeweiligen speziellen Modellkonfigurationen eingetragen werden können.

9.3 Optimierungsphase

Die Optimierungsphase, die schon im letzten Abschnitt erwähnt wurde und die für die detaillierte Modellkonfiguration steht, versuchte inspeziell für die verwendeten Daten optimale Modell zu ermitteln.

Es muss jedoch klar sein, dass keinerlei Gewissheit besteht, wirklich das insgesamt gesehen optimale Modell gefunden zu haben. Nur im Vergleich mit den übrigen berechneten Modellen kann von einem optimalen Modell gesprochen werden, nie aber in Bezug auf alle denkbaren Modellkonfigurationen. Um dieser Problematik entgegenzuwirken, versucht die zur Modellspzifikation entwickelte Methode mittels der oben erläuterten Systematik einen groben Überblick über die Eignung verschiedener Modelltypen zu geben, um so den Kreis der in Frage kommenden Modelle etwas einzugrenzen.

Zur Optimierung des benötigten Zeitaufwandes wäre hier zu eine Untersuchung interessant, welche erläutert, ob es eine ungefähre Anzahl von zu berechnenden Modellen gibt, ab der weitere Modellberechnungen in einem Vergleich nur geringfügig bessere Netzgüte erzielen. Die bei der Erstellung dieser Arbeit gewonnene Erfahrung lässt nämlich durchaus vermuten, dass bei systematischem Vorgehen bereits in einem ersten Durchgang der Modellberechnungen einige der besseren Modelle enthalten sind und es danach eines verhältnismäßig großen Aufwandes bedarf, dies merklich zu verbessern. Um diese Vermutung jedoch zu belegen, wäre die Berechnung einer großen Anzahl weiterer Modellen notwendig gewesen, was den zeitlichen Rahmen dieser Arbeit aufgrund der langen Rechenzeiten für ein Modell überschritten hätte.

Literatur - Verzeichnis

BAYRHUBER Horst, KULL Ulrich (Hrsg.) (1989):, *Linder Biologie*“, 20. Aufl., J.B. Metzler Verlag, Stuttgart, S. 204 -216.

COHEN J.W. (1985):, *Funktionelle Anatomie des Nervensystems*“, 4. Aufl., Schattauer Verlag, Stuttgart/New York.

ECCLES J.C. (1977):“ *The Understanding of the Brain*” , 2. Aufl., McGraw -Hill Verlag, New York.

HEINZ ALOIS (1997):“ Neuronale Netze”, Albert -Ludwigs Universität Freiburg :
www.informatik.uni-freiburg.de/~heinz/studbuc/studbuc/

THOMPSON R.F. (1990):, *Das Gehirn*“, Spektrum.d. Wiss. -Verlagsges., Heidelberg.

ZELL Andreas (2000):“ Simulation neuronaler Netze”, R. Oldenbourg Verlag, München Wien, ISBN 3 -486-24350-0.