


**WAS VERANLASST EINEN 2^{6+x} JÄHRIGEN
SICH MIT KÜNSTLICHER INTELLIGENZ
ZU BESCHÄFTIGEN?**




**Looks silly,
but the kids are finally
listening to her!**

**Artificial intelligence
is by far better than
your natural stupidity.**



Neue Digitalstrategie: EU will zu USA und China aufschließen

veröffentlicht am 19. 2. 2020 von APA/dpa/Reuters/AFP/sempp



Mit einer neuen Digital- und Datenstrategie will die gegenüber den USA und China ins Hintertreffen gefallene EU wieder zurück in die erste Reihe kommen. Der Schlüssel dafür soll Künstliche Intelligenz (KI) sein. Hier will Europa mit "Vertrauenswürdigkeit" punkten.

Um Europa für die Zukunftstechnik "fit" zu machen, will die Kommission mehr Geld in die Hand nehmen. Die Investitionen in Künstliche Intelligenz sollen nach ihren Plänen in diesem Jahrzehnt auf **20 Milliarden Euro pro Jahr** steigen, nachdem sie 2016 rund 3,2 Milliarden Euro erreicht hatten.

Riesiger Digital Gap

F&E Ausgaben der 50 global führenden Tech-Unternehmen:

EU: 8%

China: 11%

USA: 77%

(Quelle: Mc Kinsey)

"Je mehr Daten wir haben, desto klüger werden unsere Algorithmen", so V.D.L.

Zugang zu Daten entscheidend - riesiges ungenutztes Potenzial.

Für Bereiche wie Verkehrssektor, Gesundheitssystem oder Klimaschutz sollen eigene Datenräume geschaffen werden, in denen Daten gespeichert und ohne Hindernisse ausgetauscht werden können.

Hoffnung Künstliche Intelligenz

Zugleich will die Brüsseler Behörde den **Einsatz** Künstlicher Intelligenz (KI/Artificial Intelligence, AI) **vorantreiben** und Europa zu einem weltweit führenden Standort für "**vertrauenswürdige**"

Anwendungen von KI machen, betonte die EU-Kommissionspräsidentin.

Diese könne den Alltag jedes Einzelnen verbessern und zugleich dazu beitragen, das Ziel eines klimaneutralen Europas bis 2050 zu erreichen. Von der Leyen nannte speziell bessere Krebsdiagnosen und optimiertes Heizen, das Millionen Tonnen Öl spare.

»Zum Teufel mit der künstlichen Intelligenz«

N [redacted] ist der einzige deutschsprachige Träger des Turing-Preises (Nobelpreis der Informatik). Er ist der Erfinder der Programmiersprache Pascal. Mit dem Nachfolgesystem Oberon arbeitete er noch bis vor Kurzem auf seinem selbst gebauten Computer „Lilith“. Dafür hat er sogar die Computermäuse nach Europa gebracht. Vier Jahre bevor Steve Jobs 1984 den Macintosh vorstellte. Doch wirtschaftlich so erfolgreich wie der Apple-Gründer war er nie. Auch nicht als er die erste Drohne Anfang der 1990er-Jahre entwickelte. Lang bevor es überhaupt einen Namen für die selbst fliegenden Modellhubschrauber gab. Am 15. Februar feierte die Informatiklegende seinen 86. Geburtstag. »Die Presse am Sonntag« traf sich mit ihm zum Gespräch über künstliche Intelligenz, eine vernetzte Gesellschaft und die Digitalisierungsbestrebungen in Schulen.

Was für eine Platine haben Sie uns hier mitgebracht?

[redacted] Das war ein Bauteil, das ich Anfang der 90er-Jahre konstruiert habe. Ich kam in Kontakt mit ein paar Doktoranden von der Maschinenbau-Abteilung und hatte gehört, dass sie einen Modellhubschrauber bauen. Eben mit Computerausrüstung zum autonomen Fliegen. Und dann hab ich mich dafür interessiert und das Ganze angeschaut und mir sofort gedacht, das kann man sehr viel besser machen. Und das ist dann das Resultat (zeigt auf



AI = Death of humanity. We are playing with something we ultimately will be unable to control. I honestly don't understand why research into AI is not regulated in the same way nuclear programmes are regulated/monitored. General AI has the same destructive capability as a nuclear bomb. And I am sick of hearing how much AI would improve our lives. AI would lead to a class of people that are going to be redundant. All aspects of our lives will be regulated. These scientists clearly lack the social intelligence to comprehend this. They only focus on the perceived advantages of AI.

KI - Der Tod der Menschheit. Wir spielen mit etwas, das wir letztlich nicht kontrollieren können. Ich verstehe ehrlich gesagt nicht, warum die KI-Forschung nicht in der gleichen Weise reguliert/überwacht wird wie die Nuklearprogramme. General KI hat die gleiche Zerstörungskraft wie eine Atombombe. Und ich habe es satt zu hören, wie sehr die KI unser Leben verbessern würde. Die KI würde zu einer Klasse von Menschen führen, die überflüssig werden. Alle Aspekte unseres Lebens werden reguliert werden. Diesen Wissenschaftlern fehlt eindeutig die soziale Intelligenz, um dies zu begreifen. Sie konzentrieren sich nur auf die wahrgenommenen Vorteile der KI.

KI - Tod der Menschheit. Wir spielen mit etwas, das wir letztendlich nicht kontrollieren können. Ich verstehe ehrlich gesagt nicht, warum die Erforschung der KI nicht so reguliert wird, wie Nuklearprogramme reguliert / überwacht werden. Allgemeine KI hat die gleiche zerstörerische Fähigkeit wie eine Atombombe. Und ich habe es satt zu hören, wie sehr KI unser Leben verbessern würde. KI würde zu einer Klasse von Menschen führen, die überflüssig werden. Alle Aspekte unseres Lebens werden reguliert. Diesen Wissenschaftlern fehlt eindeutig die soziale Intelligenz, um dies zu verstehen. Sie konzentrieren sich nur auf die wahrgenommenen Vorteile der KI.

Machine learning and artificial intelligence
are constantly evolving every day—and
touching just about every corner of our lives.



\$4.99

Buy Now

DATA SCIENCE Science Guide for Everything A Data

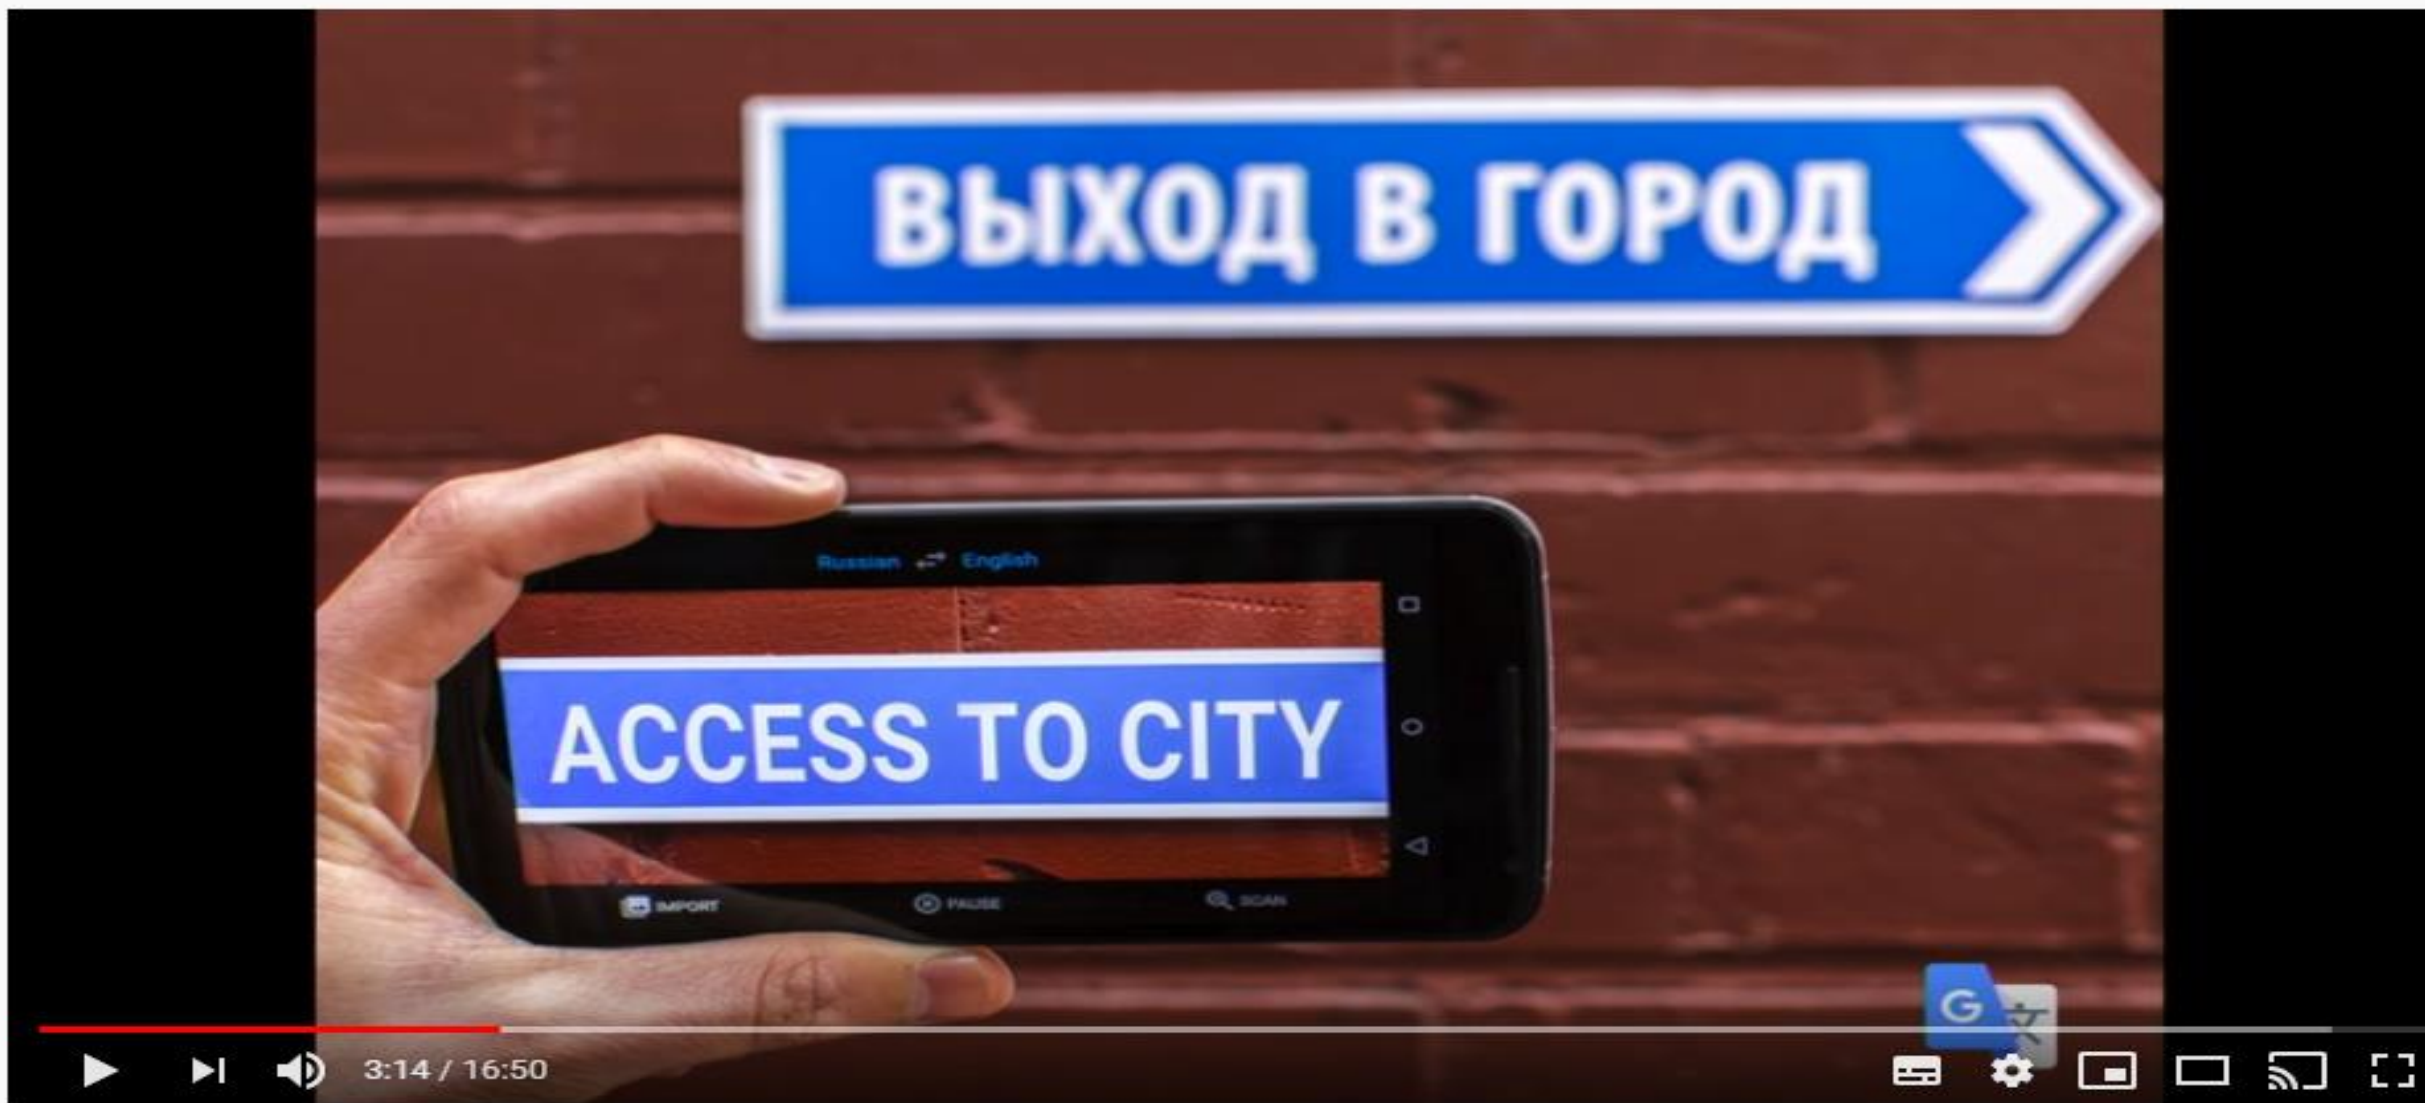
Data Science from Scratch: The #1 Data Science Gui...

Data Science from Scratch

*The #1 Data Science Guide for
Everything A Data Scientist
Needs to Know: Python, Linear
Algebra, Statistics, Coding,
Applications, Neural Networks,
and Decision Trees*

Steven Cooper





Understanding Artificial Intelligence and Its Future | Neil Nie | TEDxDeerfield



Artificial Intelligence Trends in 2019



Newchic

Short Sleeve Shirts
US\$19.56

Short Sleeve Loose Casual Shirts
Anzeige von Newchic

Der neue Billionen-Markt
WIE SIE ALS ANLEGER VON DER KÜNSTLICHEN INTELLIGENZ PROFITIEREN UND IM NÄCHSTEN JAHRZEHT ABHASSIEREN.

WordPress Übersetzungs Plugins für eine mehrsprachige...

artificial intelligence medical



Seltene Einsatzgebiete für künstliche Intelligenz | trend...



KI – Künstliche Intelligenz: Eines der größten Abenteuer der...

Useful Comparison Tables for Data Science, AI, Cloud & IoT

DIGITALISIERUNGSMONITOR 2020



Künstliche Intelligenz im Online-Marketing



Die Google-KI kann den Tod von Menschen vorhersagen



25 aktuelle Trends im Bereich Künstliche Intelligenz



Business:
ÖSTERREICHER START-UP SCHAFFT



Grafikdesign  **Merken**

Bisher war künstliche Intelligenz nicht so weit fortgeschritten, dass Roboter uns Menschen in allem übertreffen würden. Ein Start-up wollte das ändern – und scheint es geschafft zu haben. #roboter #künstlicheintelligenz #tech #gadgets #business #startups #futurezone



futurezone – Das Tech Magazin

Folgen

Fotos Kommentare

Hast du diesen Pin ausprobiert?
Füg ein Foto hinzu, um zu zeigen, wie es gelaufen ist.

Foto hinzufügen



futurezone – Das Tech Magazin hat sich etwas auf **Inspirierende Start-Ups** gemerkt.
Bisher war künstliche Intelligenz nicht so weit fortgeschritten, dass Roboter uns Menschen in allem übertreffen würden. Ein Start-up wollte das ändern – und scheint es geschafft zu haben. #roboter #künstlicheintelligenz #tech #gadgets #business #startups #futurezone **Weniger**

Karriere-News

Herrin über die künstliche Intelligenz



Stanislav Jenis

WILLKOMMEN BEI XEPHOR SOLUTIONS

Human creativity by Artificial General Intelligence!

Artificial General Intelligence (AGI)

sogenannte starke künstliche Intelligenz ermöglicht einer Maschine alle intellektuellen Aufgaben zu übernehmen, die Menschen ausführen.


Maschinendenken ist eine Weiterentwicklung des Maschinenlernens, die kreative Lösungen bietet und neue Ideen hervorbringt.

[MEHR](#)

https://www.zeit.de/2002/22/Der_multiple_Physiker/komplettansicht

<https://aeon.co/essays/how-close-are-we-to-creating-artificial-intelligence>

HINTON ET AL. TURING AWARD 2018 FOR DEEP LEARNING



<https://www.youtube.com/watch?v=I9RWTMNnvi4>

Basic Paradigm

- Observe set of examples: **training data**
- Infer something about process that generated that data
- Use inference to make predictions about previously unseen data: **test data**
- Variations on paradigm
 - **Supervised**: given a set of feature/label pairs, find a rule that predicts the label associated with a previously unseen input
 - **Unsupervised**: given a set of feature vectors (without labels) group them into “natural clusters” (or create labels for groups)

Football players, labeled by position, with height and weight data

Find canonical model of position, by statistics

Predict position of new players

Nächstes Video AUTOPLAY

ARTIFICIAL INTELLIGENCE
Ri 1:01:22

Artificial Intelligence, the History and Future - with Chris...
The Royal Institution ✓
421.362 Aufrufe

What is Machine Learning?
Learn from experience Learn from experience Follow instructions
30:53

A Friendly Introduction to Machine Learning
Luis Serrano
782.466 Aufrufe

16:51

Understanding Artificial Intelligence and Its Future | Ne...
TEDx Talks ✓
400.750 Aufrufe

BLACK JACK
WIN A SMALL FORTUNE WITH MATH
22:03

Win a SMALL fortune with counting cards-the math of...
Mathologer
Recommended for you

THE GODFATHER OF AI
Bloomberg 8:33

This Canadian Genius Created Modern AI
Bloomberg ✓
740.747 Aufrufe

$P(E|H)$
 $P(H)$
15:46

Bayes theorem, and making probability intuitive
3Blue1Brown ✓
540.827 Aufrufe

How Are Things Learned?

■ Memorization

- Accumulation of individual facts
- Limited by
 - Time to observe facts
 - Memory to store facts







Declarative knowledge

■ Generalization

- Deduce new facts from old facts
- Limited by accuracy of deduction process
 - Essentially a predictive activity
 - Assumes that the past predicts the future

Imperative knowledge

Bücher, Bücher, Bücher ...






Figure 3.2: Samples from a Gaussian mixture model. In this example, there are three components. From left to right, the first component has an isotropic covariance matrix, meaning it has the same amount of variance in each direction. The second has a covariance matrix, meaning it can control the variance separately along each axis. The third component has a full-rank covariance matrix, enabling it to control the variance separately along an arbitrary basis of directions.




Figure 3.3: The logistic sigmoid function.

The logistic sigmoid is commonly used to produce the ϕ parameter of a Bernoulli distribution because its range is $(0, 1)$, which lies within the valid range of ϕ for the Bernoulli distribution. See figure 3.3 for a graph of the sigmoid function. The sigmoid function saturates when its argument is very positive or very negative, meaning that the function becomes very flat and insensitive to small changes in its input. Another commonly encountered function is the **softplus function** (Dempster et al., 2001):

$$\zeta(x) = \log(1 + \exp(x)).$$

The softplus function can be useful for producing the β or σ parameter of a normal distribution because its range is $(0, \infty)$. It also arises commonly when manipulating expressions involving sigmoids. The name of the softplus function comes from the fact that it is a smoothed, or “softened,” version of

$$x^+ = \max(0, x).$$

(3.32)

See figure 3.4 for a graph of the softplus function.

The following properties are all useful enough that you may wish to memorize them:

$$\sigma(x) = \frac{\exp(x)}{\exp(x) + \exp(0)} \tag{3.33}$$

(3.34)

$$\frac{d}{dx} \sigma(x) = \sigma(x)(1 - \sigma(x)) \tag{3.35}$$

(3.36)

$$1 - \sigma(x) = \sigma(-x) \tag{3.37}$$

(3.38)

$$\log \sigma(x) = -\zeta(-x) \tag{3.39}$$

(3.40)

$$\frac{d}{dx} \zeta(x) = \sigma(x) \tag{3.41}$$

$$\forall x \in (0, 1), \sigma^{-1}(x) = \log\left(\frac{x}{1-x}\right) \tag{3.39}$$

(3.40)

$$\forall x > 0, \zeta^{-1}(x) = \log(\exp(x) - 1) \tag{3.40}$$

(3.41)

$$\zeta(x) = \int_{-\infty}^x \sigma(y) dy$$

$$\zeta(x) - \zeta(-x) = x$$

(3.41)

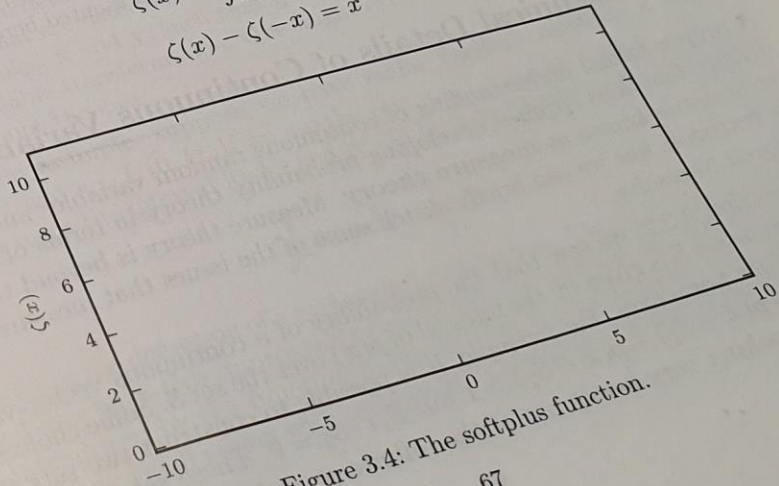


Figure 3.4: The softplus function.

The function $\sigma^{-1}(x)$ is called the **logit** in machine learning. Equation 3.41 provides extra justification for the name "softplus" for the **positive part function**, $\max\{0, x\}$. The positive part function is the counterpart of the **negative part function**, $x^- = \max\{0, -x\}$. To obtain a smooth function that is also a smooth function, one can use $\zeta(-x)$. Just as x can be recovered from its positive part, $x^- = \max\{0, -x\}$, it is also possible to recover x from its negative part via the identity $x^+ - x^- = x$, as shown in Figure 3.1. The relationship between $\zeta(x)$ and $\zeta(-x)$, as shown in Figure 3.1, is also a useful relationship.

3.11 Bayes' Rule

We often find ourselves in a situation where we know $P(y | x)$ and $P(x)$. Fortunately, if we also know $P(x)$, we can compute the desired $P(x | y)$. Using **Bayes' rule**:

$$P(x | y) = \frac{P(x)P(y | x)}{P(y)}$$

Note that while $P(y)$ appears in the formula, it is usually feasible to compute $P(y) = \sum_x P(y | x)P(x)$, so we do not need to begin with knowledge of $P(y)$. Bayes' rule is straightforward to derive from the definition of conditional probability, but it is named after the Reverend Thomas Bayes, who first discovered it by name. It is named after the Reverend Thomas Bayes, who first discovered a special case of the formula. The general version presented here was independently discovered by Pierre-Simon Laplace.

3.12 Technical Details of Continuous Variables

A proper formal understanding of continuous random variables and probability density functions requires developing probability theory in terms of a branch of mathematics known as **measure theory**. Measure theory is beyond the scope of this textbook, but we can briefly sketch some of the issues that measure theory helps to resolve. We will see that the probability of a continuous vector-valued random variable falling into a region is given by the integral of $p(\mathbf{x})$ over the set S . Some choices of S are possible to construct two sets A and B such that $A \cap B = \emptyset$. These sets are called **non-measurable sets**.

For our purposes, measure theory is more useful for describing theorems that apply to most points in \mathbb{R}^n but do not apply to some corner cases. Measure theory provides a rigorous way of describing that a set of points is negligibly small. Such a set is said to have **measure zero**. We do not formally define this concept in this textbook. For our purposes, it is sufficient to understand the intuition that a set of measure zero occupies no volume in the space we are measuring. For example, within \mathbb{R}^2 , a line has measure zero, while a filled polygon has positive measure. Likewise, an individual point has measure zero. Any union of countably many sets that each have measure zero also has measure zero (so the set of all the rational numbers has measure zero, for instance).

Another useful term from measure theory is **almost everywhere**. A property that holds almost everywhere holds throughout all space except for on a set of measure zero. Because the exceptions occupy a negligible amount of space, they can be safely ignored for many applications. Some important results in probability theory hold for all discrete values but hold "almost everywhere" only for continuous values.

Another technical detail of continuous variables relates to handling continuous random variables that are deterministic functions of one another. Suppose we have two random variables, \mathbf{x} and \mathbf{y} , such that $\mathbf{y} = g(\mathbf{x})$, where g is an invertible, continuous, differentiable transformation. One might expect that $p_{\mathbf{y}}(\mathbf{y}) = p_{\mathbf{x}}(g^{-1}(\mathbf{y}))$. This is actually not the case. As a simple example, suppose we have scalar random variables x and y . Suppose $y = \frac{x}{2}$ and $x \sim U(0, 1)$. If we use the rule $p_{\mathbf{y}}(\mathbf{y}) = p_{\mathbf{x}}(g^{-1}(\mathbf{y}))$ everywhere except the interval $[0, \frac{1}{2}]$, and it will be 1 on this interval. This means $\int p_{\mathbf{y}}(\mathbf{y})d\mathbf{y} = \frac{1}{2}$, which violates the definition of a probability distribution. This is a common problem with this approach is that it fails to account for the space introduced by the function g . Recall that the probability of an infinitesimally small region with volume δx is given by $p(\mathbf{x})\delta x$.

²The Banach-Tarski theorem provides a fun example of such sets.

Drittens braucht es ein Anwendungsverfahren, das aufgrund des Modells zu beliebigen Eingaben die korrespondierenden Ausgaben berechnet; dieser Algorithmus nutzt das Modell und wendet das Gelernte an.

Natürlich gibt es ganz verschiedene Ansätze, um so ein maschinelles Lernen zu ermöglichen. Eine einfache und durchaus effektive Methode heißt *nearest neighbor*. Dabei handelt es sich um ein Anwendungsverfahren, das in der Beispielmenge nach den ähnlichsten Eingabedaten sucht und die angegebenen Ausgabedaten als antizipierte Zuordnung für eine bekannte Eingabe verwendet. Bei Bayesschen Netzen – sie stehen für eine Klasse von Wissensmodellen – werden Abhängigkeiten zwischen Eingabe- und Ausgabekomponenten als bedingte Wahrscheinlichkeitsverteilungen in Graphen abgebildet. Wir werden uns im Folgenden die künstlichen neuronalen Netze genauer anschauen, die – aus biologischer Sicht – äußerst primitive Nachbildungen natürlicher Nervensysteme und – aus informatischer Sicht – einen bewährten und vielfach genutzten Typ von Wissensmodellen darstellen. Bsp. 8.9 erklärt Ihnen, was genau ein künstliches neuronales Netz ist.

Beispiel 8.9: Ein Mini-Gehirn im Computer

Ein künstliches neuronales Netz ist eine Verknüpfung von künstlichen Neuronen. Sie können es sich vorstellen als eine digitale Schaltung, in der nur eine Art von Gattern vorkommt. Abb. 8.13 zeigt Ihnen ein solches Gatter, ein künstliches Neuron mit drei Eingängen, die sich hier auf der linken Seite befinden, und einem Ausgang, hier auf der rechten Seite. Jedes Schaltungselement ahmt schematisch eine Nervenzelle nach, wobei das konkrete Verhalten unterschiedlich definiert werden kann. In dem skizzierten Beispiel ist es so, dass die Eingabewerte ebenso wie der Ausgabewert entweder 0 oder 1 sein können. In der einfachsten Variante ist der Ausgang auf 1, wenn der Mittelwert der Eingabewerte größer als 0,5 ist, ansonsten auf 0. Die Funktionalität entspricht einem Gatter, das genau dann 1 liefert, wenn die Mehrheit der Eingänge auf einem Gatter, das genau dann 1 liefert, wenn die Mehrheit der Eingänge auf einem Gatter, das genau dann 1 liefert, wenn die Mehrheit der Eingänge auf...





Abb. 8.13 Ein künstliches Neuron mit drei Eingängen und einem Ausgang (links) und sein natürliches Vorbild (rechts). © Susanne Staubli, Eckart Zitzler

abgerufen werden, indem ein Programm – das Anwendungsverfahren – das Verhalten dieses künstlichen Neuronenverbands simuliert: Wird eine Eingabe angelegt, reagieren die so gereizten Nervenzellen, ihre Ausgaben werden im Netz weiterverarbeitet und führen dann zu einer bestimmten Belegung der Ausgangsleitungen. Die Frage ist natürlich, wie ein künstliches neuronales Netz erlernt werden kann und wie ein entsprechendes Lernverfahren aussieht. Dies möchte ich Ihnen anhand einer exemplarischen Anwendung aufzeigen, für die diese Art des maschinellen Lernens schon früh erfolgreich eingesetzt wurde: die Handschrifterkennung. Es gilt zu erkennen, ob auf einem Pixelbild die Ziffer 2 abgebildet ist oder nicht. Die Eingabe besteht aus einem einfachen Schwarz-Weiß-Bild mit 7×5 Pixeln bzw. einer Folge von 35 Bits, und die Ausgabe ist dann 1 oder 0, je nachdem, ob eine 2 erkannt wurde oder nicht. Diese Situation ist in Abb. 8.14 unten dargestellt: Sie sehen dort auch, wie ein mehrere Neuronen umfassendes künstliches Nervensystem aussehen kann.

Beim Lernen gilt es, ein künstliches neuronales Netz zu bestimmen, das – wenn das Anwendungsverfahren sein Verhalten simuliert – für alle oder möglichst viele der vorgegebenen Beispiele die korrekte Antwort liefert. Das heißt im Einzelnen: Die Struktur des Netzes, also die Anzahl der Neuronen und ihre Verbindungen, sowie die Gewichte an den Eingängen der Neuronen müssen fixiert werden. Im einfachsten Fall gibt man die Gewichte und lässt über ein Lernverfahren nur noch die Gewichte in einzelnen Neuronen anpassen. Eine häufig gewählte Struktur ist das sogenannte künstliche Neuronenmodell, in dem jedes Neuron aus mehreren Schichten besteht. Diese Schichten sind durch Gewichte verbunden, die während des Lernens angepasst werden können.



4	Grenzen der Logik	
4.1	Das Suchraumproblem	71
4.2	Entscheidbarkeit und Unvollständigkeit	71
4.3	Der fliegende Pinguin	73
4.4	Modellierung von Unsicherheit	75
4.5	Übungen	78
5	Logikprogrammierung mit Prolog	79
5.1	Prolog-Systeme und Implementierungen	81
5.2	Einfache Beispiele	82
5.3	Ablaufsteuerung und prozedurale Elemente	82
5.4	Listen	85
5.5	Selbstmodifizierende Programme	87
5.6	Ein Planungsbeispiel	89
5.7	Constraint Logic Programming	90
5.8	Zusammenfassung	92
5.9	Übungen	94
6	Suchen, Spielen und Probleme lösen	99
6.1	Einführung	99
6.2	Uninformierte Suche	106
6.3	Heuristische Suche	112
6.4	Spiele mit Gegner	123
6.5	Heuristische Bewertungsfunktionen	128
6.6	Stand der Forschung	130
6.7	Übungen	133
7	Schließen mit Unsicherheit	137
7.1	Rechnen mit Wahrscheinlichkeiten	139
7.2	Die Methode der Maximalen Entropie	148
7.3	LEXMED, ein Expertensystem für Appendizitisdiagnose	157
7.4	Schließen mit Bayes-Netzen	172
7.5	Zusammenfassung	185
7.6	Übungen	186
8	Maschinelles Lernen und Data Mining	191
8.1	Datenanalyse	197
8.2	Das Perzeptron, ein linearer Klassifizierer	199
8.3	Nearest Neighbour-Methoden	206
8.4	Lernen von Entscheidungsbäumen	217
8.5	Kreuzvalidierung und Überanpassung	232
8.6	Lernen von	234

8.8	One-Class-Learning	242
8.9	Clustering	244
8.10	Data Mining in der Praxis	253
8.11	Zusammenfassung	257
8.12	Übungen	259
9	Neuronale Netze	265
9.1	Von der Biologie zur Simulation	266
9.2	Hopfield-Netze	271
9.3	Neuronale Assoziativspeicher	277
9.4	Lineare Netze mit minimalem Fehler	284
9.5	Der Backpropagation-Algorithmus	291
9.6	Support-Vektor-Maschinen	298
9.7	Deep Learning	299
9.8	Kreativität	305
9.9	Anwendungen von Neuronalen Netzen	308
9.10	Zusammenfassung und Ausblick	308
9.11	Übungen	309
10	Lernen durch Verstärkung (Reinforcement Learning)	313
10.1	Einführung	313
10.2	Die Aufgabenstellung	316
10.3	Uninformierte kombinatorische Suche	317
10.4	Wert-Iteration und Dynamische Programmierung	319
10.5	Ein lernender Laufroboter und seine Simulation	322
10.6	Q-Lernen	324
10.7	Erkunden und Verwerten	328
10.8	Approximation, Generalisierung und Konvergenz	329
10.9	Anwendungen	330
10.10	AlphaGo, der Durchbruch beim Go-Spiel	331
10.11	Fluch der Dimensionen	333
10.12	Zusammenfassung und Ausblick	334
10.13	Übungen	335
11	Lösungen zu den Übungen	337
11.1	Einführung	337
11.2	Aussagenlogik	338
11.3	Prädikatenlogik	340
11.4	Grenzen der Logik	342
11.5	Prolog	342
11.6	Suchen, Spielen und Probleme lösen	344

für die verschiedensten Anwendungen bereit. Der Leser möge sich von Abb. 1.2 inspirieren lassen. Genau wie in der Medizin gibt es auch in der KI keine universelle Methode für alle Anwendungsbereiche, aber eine große Zahl möglicher Behandlungen für die verschiedensten großen und kleinen Probleme des Alltags.

Der Erforschung des menschlichen Denkens auf etwas höherer Ebene widmet sich die **Kognitionswissenschaft** (engl. cognitive science). Wie auch die Hirnforschung liefert dieses Gebiet viele wichtige Ideen für die praktische KI. Umgekehrt liefern die Algorithmen und Implementierungen wiederum wichtige Rückschlüsse auf die Funktionsweise des menschlichen Schließens. So stehen diese drei Gebiete in einer fruchtbaren interdisziplinären Wechselwirkung. Gegenstand dieses Buches ist jedoch überwiegend die prozessorientierte KI als Teildisziplin der Informatik.

Im Umfeld von Intelligenz und Künstlicher Intelligenz gibt es viele interessante philosophische Fragen. Wir Menschen haben ein Bewusstsein. Das heißt, wir können über uns selbst nachdenken oder sogar darüber nachdenken, dass wir über uns selbst nachdenken. Wie kommt dieses Bewusstsein zustande? Viele Philosophen und Neurologen glauben heute, dass die Seele und das Bewusstsein an die Materie, das heißt, an das Gehirn geknüpft sind. Damit könnte die Frage, ob eine Maschine Seele oder Bewusstsein haben kann, in der Zukunft irgendwann relevant werden. Beim Leib-Seele-Problem zum Beispiel geht es darum, ob die Seele an den Körper gebunden ist oder nicht. Wir werden diese Fragen hier nicht diskutieren. Der interessierte Leser wird verwiesen auf [Spe03, Spe04] und aufgefordert, sich während des Studiums der KI-Techniken über diese Fragen selbst eine Meinung zu bilden.

1.1.2 Der Turing-Test und Chatterbots

Alan Turing hat sich durch seine Definition einer intelligenten Maschine auch als früherer Pionier in der KI einen Namen gemacht. Dazu muss die fragliche Maschine folgenden Test bestehen. Die Testperson Alice sitzt in einem abgeschlossenen Raum mit zwei Computerterminals. Ein Terminal ist mit der Maschine verbunden, das andere mit der gutwilligen Person Bob. Alice kann nun an beiden Terminals Fragen eintippen. Sie hat die Aufgabe, nach fünf Minuten zu entscheiden, an welchem Terminal die Maschine antwortet. Die Maschine besteht den Test, wenn sie Alice in mindestens 30 % der Fälle täuschen kann [Tur50].

Dieser Test ist philosophisch sehr interessant. Für die praktische KI, die sich mit der Problemlösung beschäftigt, ist er als Test jedoch wenig relevant. Die Gründe sind ähnlich wie bei den oben erwähnten Braitenberg-Vehikeln (siehe Aufgabe 1.3).

Der KI-Pionier und Gesellschaftskritiker Joseph Weizenbaum hat als erster ein Programm mit dem Namen **Eliza** entwickelt, welches auf eine Testperson wie ein menschlicher Psychologe antworten sollte [Wei66]. Er konnte zeigen, dass dies tatsächlich in vielen Fällen erfolgreich war. Angeblich hat sich seine Sekretärin oft und lang mit diesem Programm unterhalten. Heute gibt es im Netz...


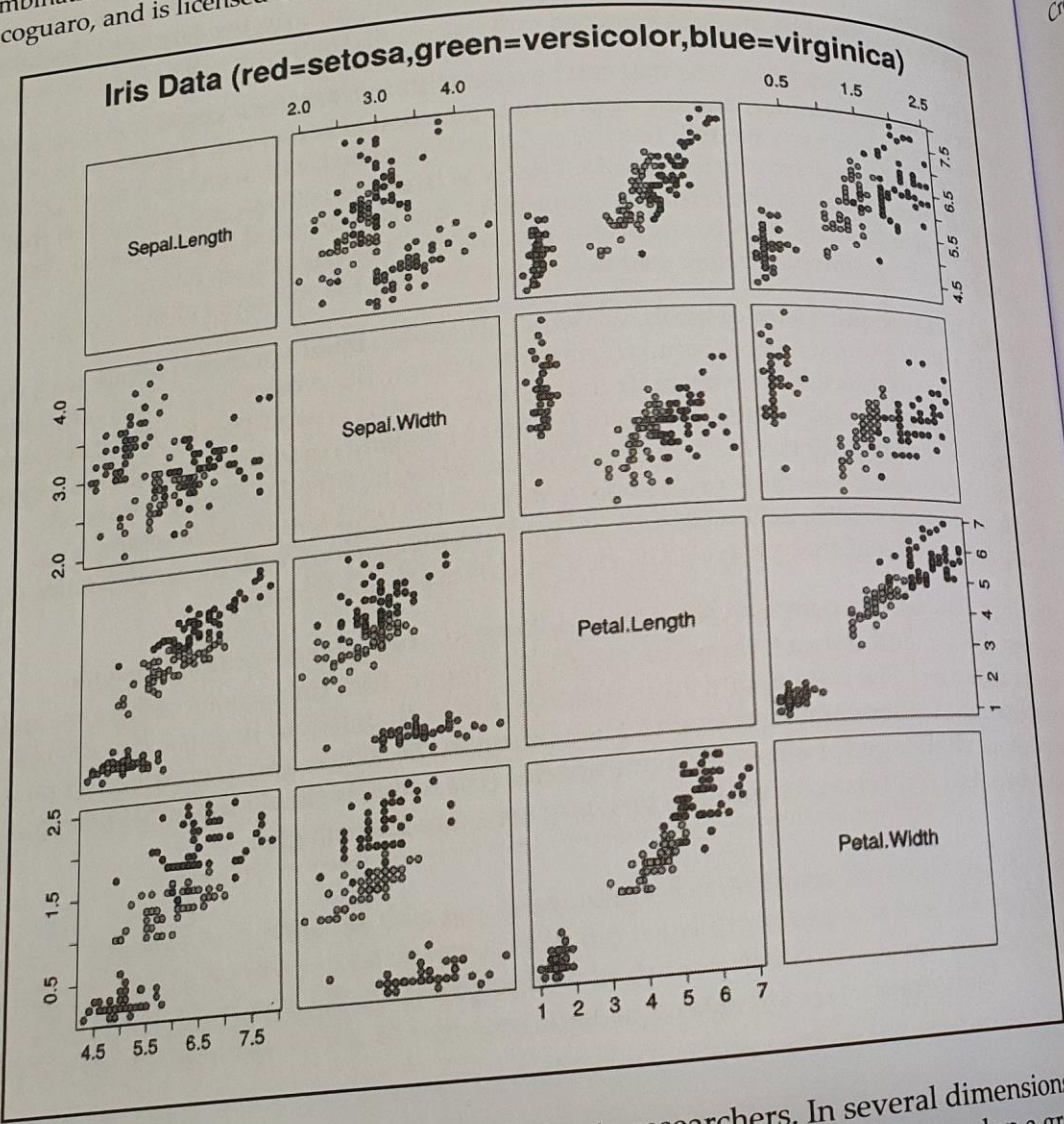


Abb. 1.2 Ein kleiner Ausschnitt aus dem Angebot an KI-Verfahren

Because the data is four-dimensional, it cannot be visualized directly, but we can plot each combination of two features separately into a grid. This image is courtesy of Wikipedian Nicoguaro, and is licensed CC BY 4.0:



...this dataset would be interesting to researchers. In several dimensions, ... and *Iris virginica* overlap a great ...

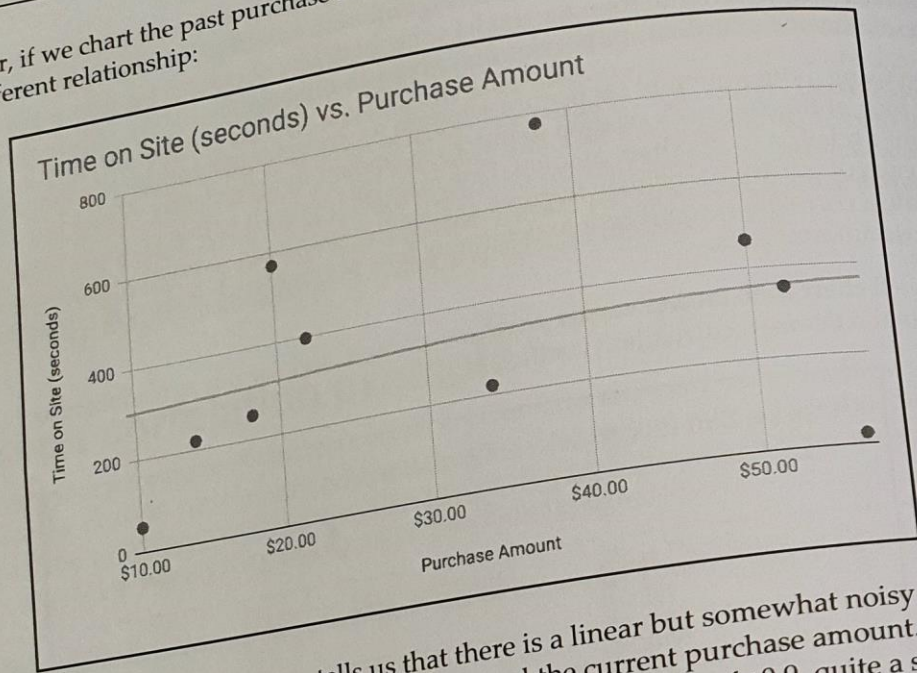
Let's finally implement an SVM to solve this problem for us.
Create a new folder called Ch5-SVM and add the following package.json file:

```
{
  "name": "Ch5-SVM",
  "version": "1.0.0",
  "description": "ML in JS Example for Chapter 5 - Support Vector Machine",
  "main": "src/index.js",
  "author": "Burak Kanber",
  "license": "MIT",
  "scripts": {
    "build-web": "browserify src/index.js -o dist/index.js -t [ babelify --presets [ env ] ]",
    "build-cli": "browserify src/index.js --node -o dist/index.js -t [ babelify --presets [ env ] ]",
    "start": "yarn build-cli && node dist/index.js"
  },
  "dependencies": {
    "babel-core": "^6.26.0",
    "babel-plugin-transform-object-rest-spread": "^6.26.0",
    "babel-preset-env": "^1.6.1",
    "babelify": "^8.0.0",
    "browserify": "^15.1.0",
    "libsvm-js": "^0.1.3",
    "ml-cross-validation": "^1.2.0",
    "ml-dataset-iris": "^1.0.0",
    "ml-random-forest": "^1.0.2"
  }
}
```

Once the file is in place, run `yarn install` to install all the dependencies. Rather than using a `data.js` file, we will use the Iris dataset that comes with the MLJS library.
Next, create an `src` folder and an `index.js` file. At the top of `index.js`, import the following:

```
import SVM from 'libsvm-js/asm';
import IrisDataset from 'ml-dataset-iris';
```

However, if we chart the past purchase amount versus current purchase amount, we see a very different relationship:



In this case, our visual inspection tells us that there is a linear but somewhat noisy relationship between the past purchase amount and the current purchase amount. Calculating the correlation coefficient gives us a correlation value of $+0.9$, quite a strong linear relationship!

This type of analysis tells us that we can ignore the time on site data when training our model, as there seems to be little to no statistical significance in that information. By ignoring time on site data, we can reduce the number of dimensions we need to train our model on by one, allowing our model to better generalize data and also improve performance.

If we had 48 other numerical dimensions to consider, we could simply calculate the correlation coefficient for each of them and discard each dimension whose correlation falls beneath some threshold. Not every feature can be analyzed using correlation coefficients, however, so you can only apply the Pearson algorithm to those features where such a statistical analysis makes sense; it would not make sense to use Pearson correlation to filters for different dimensions representing product category, for instance. You can, and basis techniques that can

Unfortunately, a thorough explanation of all the possible feature extraction and feature selection algorithms and tools is not possible here; you will have to research various techniques and determine which ones fit the shape and style of your features and data.

Some algorithms to consider for filter techniques are the Pearson and Spearman correlation coefficients, the chi-squared test, and information gain algorithms such as the Kullback–Leibler divergence.

Approaches to consider for wrapper techniques are optimization techniques such as genetic algorithms, tree-search algorithms such as best-first search, stochastic techniques such as random hill-climb algorithms, and heuristic techniques such as recursive feature elimination and simulated annealing. All of these techniques aim to select the best set of features that optimize the output of your model, so any optimization technique can be a candidate, however, genetic algorithms are quite effective and popular.

Feature extraction has many algorithms to consider, and generally focuses on cross-correlation of features in order to determine new features that minimize some error function; that is, how can two or more features be combined such that a minimum amount of data is lost. Relevant algorithms include PCA, partial least squares, and autoencoding. In NLP, latent semantic analysis is popular. Image processing has many specialized feature extraction algorithms, such as edge detection, corner detection, and thresholding, and further specializations based on problem domain such as face identification or motion detection.

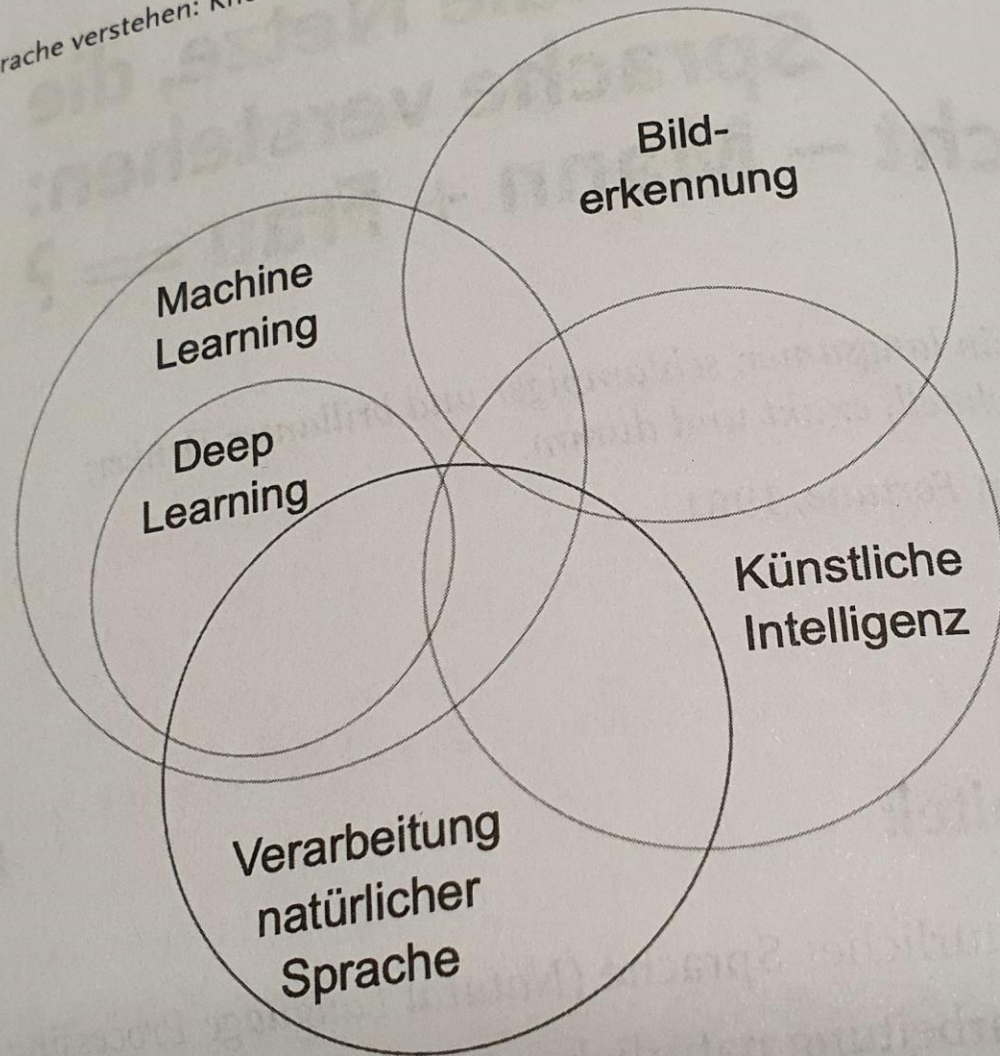
Cleaning and preparing data

Feature selection is not the only consideration required when preprocessing your data. There are many other things that you may need to do to prepare your data for the algorithm that will ultimately analyze the data. Perhaps there are measurement errors that create significant outliers. There can also be instrumentation noise in the data that needs to be smoothed out. Your data may have missing values for some features. These are all issues that can either be ignored or addressed, depending, as always, on the context, the data, and the algorithm involved.

Additionally, the algorithm you use may require the data to be normalized to some range of values. Or perhaps your data is in a different format that the algorithm cannot use, as is often the case with neural networks which expect you to provide a vector of values, but you have JSON objects that come from a database. Sometimes you need to analyze only a specific subset of data from a larger source. If you're working with images you may need to resize, scale, pad, crop, or reduce the image to grayscale.

Kapitel 11

Neuronale Netze, die Sprache verstehen: Knecht – Mann + Frau == ?



Wir werden uns in diesem Kapitel zunächst mit einem älteren Fachgebiet befassen, das einige Überschneidungen mit Deep Learning aufweist, nämlich mit der Verarbeitung natürlicher Sprache (Natural Language Processing, NLP). Dieses Fach-



- Verwendung der Wörter Merkmale (wie Person)
- Verwendung der Sätze die gleiche Person/de
- Verwendung der Wörter Dokument.

Bei den NLP-Aufgaben eines Textbereichs von benannten Merkmalen (wie Koreferenzen) Person, einen Ort fehlende Informa-

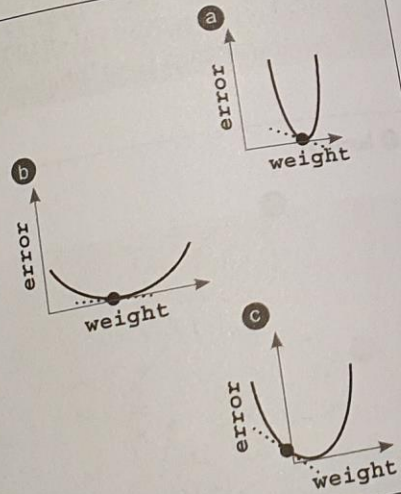

Machine Learning waren die mechanische Modellbreitung zwischen rekurrente

In diesem und dem nächsten

Iteration



Iteration



Hier sind noch einige Anmerkungen. Der Großteil des Lernens (Änderung des Gewichts **a** bei dem Gewicht **a** mit der größten Eingabe statt, weil die Eingabe nicht immer unbedingt von Vorteil. Eine größere Verteilung der Gewichte...

5.4 Einfrieren eines Gewichts: Was bewirkt das?

Dieses Experiment ist theoretisch gesehen etwas fortgeschrittener, aber ich denke, es ist eine ausgezeichnete Übung, um zu verstehen, wie die Gewichte sich gegenseitig beeinflussen. Du führst das Training erneut durch, allerdings wird Gewicht **a** nicht angepasst. Beim Training werden nur **b** und **c** verwendet (weights[1] und weights[2]).

```
def neural_network(input, weights):
    out = 0
    for i in range(len(input)):
        out += (input[i] * weights[i])
    return out
```

```
def ele_mul(scalar, vector):
    out = [0,0,0]
    for i in range(len(out)):
        out[i] = vector[i] * scalar
    return out
```

```
toes = [8.5, 9.5, 9.9, 9.0]
wlrec = [0.65, 0.8, 0.8, 0.9]
nfans = [1.2, 1.3, 0.5, 1.0]
```

```
win_or_lose_binary = [1, 1, 0, 1]
true = win_or_lose_binary[0]
```

```
alpha = 0.3
```

```
weights = [0.1, 0.2, -0.1]
```

```
input = [toes[0], wlrec[0], nfans[0]]
```

```
for iter in range(3):
```

```
    pred = neural_network(input, weights)
```

```
    error = (pred - true) ** 2
```

```
    delta = pred - true
```

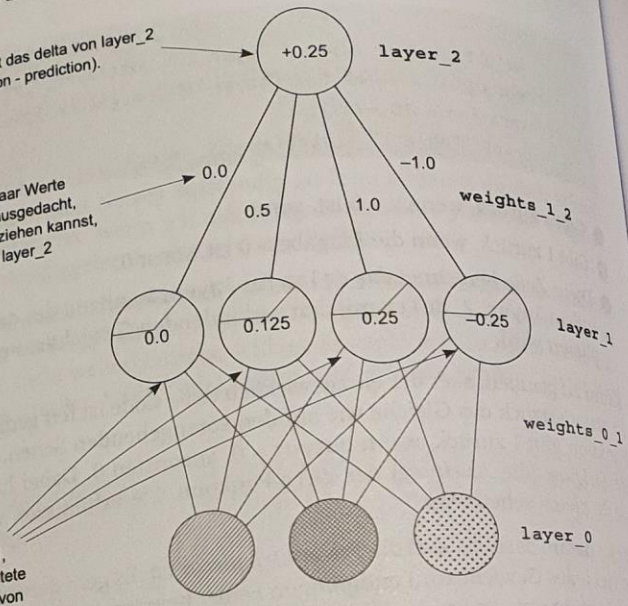
```
    weights = ele_mul(delta, input)
```

Kapitel 6

Das erste tiefe neuronale Netz: Einführung in Backpropagation

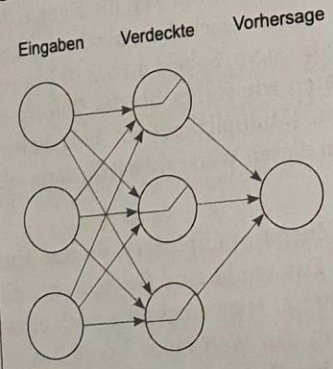
Ich habe mir ein paar Werte für die Gewichte ausgedacht, damit du nachvollziehen kannst, wie das delta von layer_2 sie durchläuft.

Die deltas von layer_1, die tatsächlich gewichtete Versionen des deltas von layer_2 sind.



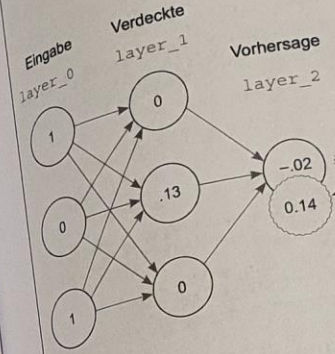
6.23 Eine Iteration der Backpropagation

1 Initialisierung der Gewichte und der Daten des Netzes



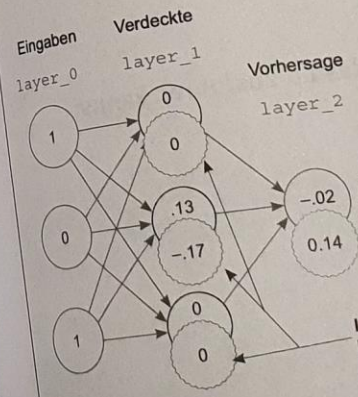
```
import numpy as np
np.random.seed(1)
def relu(x):
    return (x > 0) * x
def relu2deriv(output):
    return output > 0
lights = np.array([[ 1, 0, 1 ],
                  [ 0, 1, 1 ],
                  [ 0, 0, 1 ],
                  [ 1, 1, 1 ]])
walk_stop = np.array([[ 1, 1, 0, 0 ]]).T
alpha = 0.2
hidden_size = 3
weights_0_1 = 2*np.random.random(
    (3,hidden_size)) - 1
weights_1_2 = 2*np.random.random(
    (hidden_size,1)) - 1
```

2 VORHERSAGE + VERGLEICH: Treffen einer Vorhersage und Berechnen von Fehler und delta der Ausgabe



```
layer_0 = lights[0:1]
layer_1 = np.dot(layer_0, weights_0_1)
layer_1 = relu(layer_1)
layer_2 = np.dot(layer_1, weights_1_2)
error = (layer_2 - walk_stop[0:1])**2
layer_2_delta = (layer_2 - walk_stop[0:1])
```

3 ERLERNEN: Backpropagation von layer_2 nach layer_1



```
layer_0 = lights[0:1]
layer_1 = np.dot(layer_0, weights_0_1)
layer_1 = relu(layer_1)
layer_2 = np.dot(layer_1, weights_1_2)
error = (layer_2 - walk_stop[0:1])**2
layer_2_delta = (layer_2 - walk_stop[0:1])
layer_1_delta = layer_2_delta.dot(weights_1_2.T)
layer_1_delta *= relu2deriv(layer_1)
```

Von den Grundlagen Neuronaler Netze über Machine Learning bis hin zu Deep-Learning-Algorithmen
 Anschauliche Diagramme, Anwendungsbeispiele in Python und der Einsatz von NumPy
 Keine Vorkenntnisse in Machine Learning oder höherer Mathematik erforderlich

Aus dem Inhalt:

- Parametrische und nichtparametrische Modelle
- Überwachtes und unüberwachtes Lernen
- Vorhersagen mit mehreren Ein- und Ausgaben
- Fehler messen und verringern
- Hot and Cold Learning
- Batch- und stochastischer Gradientenabstieg
- Überanpassung vermeiden
- Generalisierung
- Dropout-Verfahren
- Backpropagation und Forward Propagation
- Bilderkennung
- Verarbeitung natürlicher Sprache (NLP)
- Sprachmodellierung
- Aktivierungsfunktionen
- Sigmoid-Funktion
- Tangens hyperbolicus
- Softmax
- Convolutional Neural Networks (CNNs)
- Recurrent Neural Networks (RNNs)
- Long Short-Term Memory (LSTM)
- Deep-Learning-Framework erstellen

Deep Learning muss nicht kompliziert sein. Mit diesem Buch lernst du anhand vieler Beispiele alle Grundlagen, die du brauchst, um Deep-Learning-Algorithmen zu verstehen und anzuwenden. Dafür brauchst du nichts weiter als Schulmathematik und Kenntnisse der Programmiersprache Python. Alle Codebeispiele werden ausführlich erläutert und mathematische Hintergründe anhand von Analogien veranschaulicht.

Der Autor erklärt leicht verständlich, wie Neuronale Netze lernen und wie sie mit Machine-Learning-Verfahren trainiert werden können. Du erfährst, wie du dein erstes Neuronales Netz erstellst und wie es mit Deep-Learning-Algorithmen Bilder erkennen sowie natürliche Sprache verarbeiten und modellieren kann. Hierbei kommen Netze mit mehreren Schichten wie CNNs und RNNs zum Einsatz.

Fokus des Buches ist es, Neuronale Netze zu trainieren, ohne auf vorgefertigte Python-Frameworks zurückzugreifen. So verstehst du Deep Learning von Grund auf und kannst in Zukunft auch komplexe Frameworks erfolgreich für deine Projekte einsetzen.


Über den Autor:

Andrew W. Trask ist Doktorand an der Oxford University und als Research Scientist für DeepMind tätig. Zuvor war er Researcher und Analytics Product Manager bei Digital Reasoning, wo er u.a. das größte künstliche Neuronale Netz der Welt trainierte.


Außerdem bei mitp:



ISBN 978-3-95845-813-0



ISBN 978-3-95845-995-3



ISBN 978-3-95845-838-3



MENSCH, Maschine!

Wer zeigt hier wem den Weg?



„WIR DÜRFEN KÜNSTLICHE INTELLIGENZ NICHT VERTEUFELN“

Haben Sie heute bereits Künstliche Intelligenz verwendet, Herr Wahlster?

Ja, am Morgen habe ich mir meine persönliche Presseschau angesehen. Die wird mit KI auf Grundlage meiner Lesepräferenzen erstellt. Bevor ich mit dem Auto losgefahren bin, habe ich wie immer bei Google Maps nachgesehen, wie die Verkehrslage ist. Dahinter steckt ein komplexer KI-Algorithmus, der mittels vieler Faktoren wie Verkehrsdichte, Staus und Umleitungen abschätzt, wann ich an meinem Ziel ankommen werde.

Was genau ist daran intelligent?

Solche KI-Algorithmen interpretieren digitale Massendaten inhaltlich auf Grundlage großer Wissensbasen. Sie ziehen ei...

Die Angst, KI könnte uns überwachen oder einst gar ersetzen, ist groß. Eben deshalb brauchen wir die Technik, sagt Deutschlands wichtigster

Parfüm im individuellen Flakon, das zu meiner Frau passt, oder der Sportschuh, den ich selbst entworfen habe.

Sie forschen bereits seit den siebziger Jahren an Künstlicher Intelligenz. Wie sind die großen Fortschritte in letzter Zeit zu erklären?

Damit Computer selbst lernen können, brauchen sie extrem große Datenmengen als Trainingsdaten. Die Internet-Technologie, die Cloud-Technologie und die sozialen Medien, bei denen Milliarden Menschen jeden Tag Datenspuren hinterlassen, haben diese Grundvoraussetzung geschaffen. Durch das Internet der Dinge wurde...

... Webseiten durch
...ektororientierte Programm...



{BMU VERLAG}

Mic

... können die monatlichen
...lk" der DigitalSociety
...//digitalsociety.at
...g in Outlook, Google...
...er.at/calendar.aspx

... zusammengeführt und mithilfe der KI und Methoden
des MASCHINELLEN LERNENS weiterverarbeitet. Das
Geschäft bestimmt künftig, wer diese Daten der intel-
ligenten Gegenstände und Maschinen mit jenen Daten
der Nutzer zusammenbringt.

Zum ersten Mal flächendeckend setzte der digi-
tale Wandel Anfang der siebziger Jahre ein. Indus-
trieunternehmen optimierten ihre
Produktion mit Elektronik und IT.
Der Computer wurde nach und nach
massentauglich. Seit einigen Jahren
erleben wir zum zweiten Mal, wie
die Digitalisierung alle Bereiche
verändert. Dieses zweite Entwick-
lungslevel lässt sich knapp mit drei
Worten beschreiben: smart, vernetzt,
autonom. Zentral ist dabei,
dass Produkte und Dienstleistungen
immer individueller werden. Dazu
braucht man lernende Systeme, die
etwa selbstständig Montagepläne
für ständig neue Produktdesigns
erstellen.

Maschinen, Autos oder Haus-
haltsgeräte sind mit eingebetteter
Elektronik über das Internet mitei-
nander verbunden. Diese intelligenten,
vernetzten Objekte versorgen
uns mittels ihrer Sensoren mit Un-
mengen von Realweltdaten. Diese
sind die Grundlage und quasi das
Trainingsmaterial für lernende Sys-
teme. Gleichzeitig lassen sich diese
Daten durch KI-Technologien analysieren
und interpretieren. So entstehen
neue Geschäftsmodelle, Applikationen
und Apps, sogenannte Smart
Services, die den Nutzen für uns in
den Mittelpunkt rücken können.

Autos sind heute bereits intelli-
gent und mit dem Internet verbun-
den. In Zukunft kommt ein neuer
Service für die Insassen, das auto-
nome Fahren. Das Auto selbst wird
zum lernenden System. Der Mehrwert,
also das Leistungsversprechen an uns:
Unfälle und Verkehrstote werden
drastisch zurückgehen, Fahren wird
sicher. Kein Unternehmen kann allein
die dafür notwendigen Daten für ein
Smart Service erheben. Das auto-
nome Fahren braucht Zugriff auf
Kartendaten und Verkehrsinforma-
tionen von anderen Anbietern als dem
Autohersteller selbst. Diese benötigten
Daten aus verschiedenen Quellen werden

Glossar

EIN ALGORITHMUS
ist eine genaue Berechnungsvor-
schrift für Computer, um Aufgaben
zu lösen. Lernalgorithmen können
aus Lerndaten Modelle abstrahieren
und auf neue Daten anwenden.

KÜNSTLICHE INTELLIGENZ (KI)
Eine allgemein akzeptierte De-
finition gibt es nicht. KI ist ein
Teilgebiet der Informatik, das
versucht, kognitive Fähigkeiten wie
Lernen, Planen oder Problemlösen in
Computern zu realisieren. Zugleich
beschreibt KI Systeme, die ein
Verhalten zeigen, für das gemeinhin
menschliche Intelligenz vorausge-
setzt wird. Ziel von KI-Systemen
(lernenden Systemen): Maschinen,
Roboter und Softwaresysteme
bearbeiten und lösen abstrakt be-
schriebene Aufgaben und Probleme
eigenständig, ohne jeden Schritt
programmieren zu müssen.

LERNENDE SYSTEME
sind Maschinen, Roboter und
Softwaresysteme, die mithilfe von
Lernalgorithmen im laufenden
Betrieb selbstständig weiterlernen:
Sie basieren auf Methoden des
maschinellen Lernens.

MASCHINELLES LERNEN
ist eine grundlegende Methode von
KI, die darauf zielt, dass Maschinen
ohne explizite Programmierung
eines konkreten Lösungswegs
automatisiert sinnvolle Ergebnisse
liefern. Spezielle Algorithmen ent-
wickeln aus Beispieldaten Modelle,
die auf zuvor noch nicht gesehene
Daten angewendet werden können.

leeren Elektrofahrzeuge wenden und steuern die
nächstgelegene Ladestation an, um bald neue Fahr-
gäste zu befördern.

Künstliche Intelligenz hat eine Revolution in Gang ge-
setzt, deren Ausmaße noch nicht abzuschätzen sind.
Das gilt für die datengetriebene Produktion, die

Wenn Emma auf ihrem Weg zur Arbeit an ihre Stu-
dienzeit denkt, merkt sie, was sich alles verändert
hat: Der allmorgendliche Stau, sie
musste immer einen Parkplatz su-
chen, vor allem aber der Stress,
pünktlich zu sein – 2030 sind das
alles kaum noch vorstellbare Pro-
bleme. Entspannt lehnt sich Emma
im Autositz zurück. Die Steuerung
des ÖV-Shuttles wird vollstän-
dig vom Autopiloten übernom-
men. Emma liest, hört und sieht
sich währenddessen durch die
Nachrichten.

Kurz bevor das Shuttle Emmas
Firma erreicht, taucht plötzlich ein
Junge zwischen parkenden Autos
auf, läuft auf die Straße und droht,
vom Shuttle erfasst zu werden. Ein
entgegenkommendes, ebenfalls au-
tonomes Fahrzeug hat den Jungen
aber aufgrund des besseren Sicht-
winkels noch früher erkannt und
eine Warnung an das ÖV-Shuttle
übermittelt, sodass es rechtzeitig
bremsen kann. Kurz hebt Emma
den Kopf, um dann wieder in der
Lektüre zu versinken. Solche Vor-
fälle erlebt sie häufig, aber sie ist es
inzwischen gewohnt, den auto-
nomen Autos zu vertrauen, auch weil
noch nie etwas passiert ist.

Trotz der kurzen Unterbre-
chung erreicht Emma pünktlich
ihre Firma. Zwar nehmen sehr viele
Personen morgens die ÖV-Shuttles
ins Gewerbegebiet, dennoch kom-
men viele Autos. Parkplätze aber
müssen nicht gesucht werden. Die
nächstgelegene Ladestation an, um bald neue Fahr-
gäste zu befördern.

und Start-ups, denen der Datenreichtum große Chan-
cen für neue Geschäftsideen eröffnet. Die Menschen
wiederum profitieren von den Vorteilen der neuen
Anwendungen, den Leistungsversprechen. Indem ler-
nende Systeme sich immer weiter verbreiten, setzen
sie Unternehmen und Menschen unter einen gewissen
Transformationsdruck: Das Wettrennen um die besten
KI-Anwendungen und -Produkte hat begonnen, und
auch für uns ist lebenslanges Lernen trotz aller Er-
leichterungen selbst in Bezug auf unsere Alltagsgegen-
stände keine leere Forderung, sondern schlicht Realität.

In der industriellen Produktion, einem der wich-
tigsten Anwendungsbereiche für lernende Systeme, ist
Deutschland als Fabrikausstatter der Welt traditionell
stark. In der sogenannten Industrie
4.0 entlasten intelligente Maschinen
die Menschen schon heute von kör-
perlich schwerer Tätigkeit und ein-
tönigen Routineaufgaben. Die Ange-
stellten arbeiten künftig noch enger
mit Robotern zusammen. Sie wer-
den in einem sich selbst steuernden
Produktionssystem vielmehr zu Ent-
scheidern, die mit Erfahrungswissen
Abläufe überwachen und in unvor-
hersehbaren Problemsituationen
eingreifen.

Emma arbeitet in der Endmontage
einer Fabrik, in der intelligente
Haushaltsgeräte hergestellt wer-
den. Sie sind Teil des sogenann-
ten INTERNETS DER DINGE (INTER-
NET OF THINGS), also Geräten, die
miteinander und über eine Cloud
verbunden sind, um Informationen
auszutauschen. Jeder Kunde hat un-
terschiedliche Bedürfnisse, und in-
zwischen bedeutet es keinen unbezahlbaren Mehraufwand mehr, De-
sign und Fähigkeiten der Geräte oft kundenindivi-
duell anzupassen. Unikatsproduktion ist massentaug-
lich geworden.

Über ihr Smartphone ist Emma mit dem unter-
nehmensweiten IT-System verbunden. Es bereitet für
sie die nötigen Informationen zur Arbeitsplanung auf.
Statt wie sonst im Produktionsbereich für die Küchen-
geräte, soll sie heute ihren Kollegen Max vertreten
und intelligente Waschmaschinen mit Assistenzfunktio-
nen gemeinsam mit zwei Da...

Trotz aller
Erleichterungen
ist lebenslanges
Lernen selbst
für Alltagsgegen-
stände keine
leere Forderung,
sondern schlicht
Realität

... ihr heute, die für s
... lage zu bedienen.
... die jeweils ansteh
... feld einblendet. De
... an ihre Bedürfniss
... tem der Fabrik we
... benötigt, und stel
... tione und anstren
... ter selbstständig
... Sie reichen Emm
... galen oder heber
... letzte Teil aus ein
... die Regale selbst
... Gegen Mitta

maschine ausf
Wartung organ
Die Arbeit
ginnen. Für de
die autonom j
bahnhof in de
in ein sogenan
Fahrgemeinsc
ab. Schließlic
ein intelligen
fasst das V