

Universität Leipzig
Fakultät für Mathematik und Informatik
Institut für Informatik

Bachelorarbeit

Multi-Label Klassifikation am Beispiel sozialwissenschaftlicher Texte

Leipzig, Oktober 2013

vorgelegt von
Jonas Nathanael Philipp
Studiengang Informatik

Betreuender Hochschullehrer:

Prof. Dr. Gerhard Heyer
Fakultät für Mathematik und Informatik
Abteilung Automatische Sprachverarbeitung

Inhaltsverzeichnis

1. Einleitung	3
2. Grundlagen	5
2.1. Klassifikationsverfahren	6
2.1.1. Naive Bayes	6
2.1.2. Support Vector Machine	7
2.1.3. Supervised Latent Dirichlet Allocation	8
2.2. Multi-Label Klassifikation	11
2.2.1. Problemtransformationen	12
2.2.2. Evaluation	13
2.3. Preprocessing	15
2.4. Frameworks	16
3. Korpus	18
4. Topic Modell Multi-Label Learner	21
5. Ergebnisse	25
6. Fazit	33
7. Kurzzusammenfassung	35
8. Literaturverzeichnis	36
Anhang	38
A. Topic Modell Multi-Label Learner Ergebnisse	38
A.1. Schwellwert 0,08	38
A.2. Schwellwert 0,09	40
A.3. Schwellwert 0,10	43
A.4. Schwellwert 0,11	45
A.5. Schwellwert 0,12	47
A.6. Schwellwert 0,13	50

Inhaltsverzeichnis

B. Evaluationsergebnisse	53
B.1. Naive Bayes	53
B.1.1. Korpus A	53
B.1.2. Korpus B	60
B.2. SVM	67
B.2.1. Korpus A	67
B.2.2. Korpus B	70
B.3. SLDA	72
B.3.1. Korpus A	72
B.3.2. Korpus B	77
 Erklärung	 82

1. Einleitung

Durch die zunehmende Digitalisierung sind auch immer mehr sozialwissenschaftliche Texte digital verfügbar. Dies ist ein Problem der quantitativen Inhaltsanalyse, denn als Forscher hat man keine Möglichkeit so viele Dokumente zu klassifizieren, wie man gerne möchte. Insbesondere ist dies mit einem sehr hohem Aufwand der manuellen Klassifikation und der anschließenden Qualitätssicherung verbunden, weshalb es in der Praxis oftmals zu einer Reduktion der Stichprobengröße kommt.

Die automatische Sprachverarbeitung bietet die Möglichkeit diese Klassifikation maschinell zumachen. Allerdings ist die maschinelle Klassifizierung der Texte nicht unproblematisch.[10]

Die heute gebräuchlichen Klassifikationsverfahren, sind in der Regel Binäre, das heißt sie können lediglich zwischen zwei Labels unterscheiden. Wenn eine Klassifikation in mehr als zwei Labels erfolgen soll, muss für jedes Label ein eigener Klassifikator trainiert werden. Zudem können mit den Klassifikatoren nicht alle Labels in gleicher Qualität erkannt werden. So sind Labels die nur durch ein semantisches Verständnis des Textes erschlossen werden können nicht zuverlässig zu klassifizieren.

Scharkow[10] hat das Problem der Klassifizierung von Texten allerdings dahin vereinfacht, als dass er pro Text lediglich nur ein Label zulässt. Ein Text behandelt allerdings in der Regel mehr als nur ein Thema und sollte somit auch bei einer automatischen Klassifikation mehreren Labels zugeordnet werden können.

Der Ausgangspunkt für diese Arbeit ist nun die Frage ob ein automatisches Multi-Labeling bessere Ergebnisse liefert. Insbesondere geht es um eine Evaluation zwischen binären Klassifikationsverfahren und Topic Modellen. Als Vertreter der binären Klassifikationsverfahren werden die Verfahren Naive Bayes und Support Vector Machine(SVM) untersucht, als Vertreter der Topic Modelle das Supervised Latent Dirichlet Allocation(SLDA).

Sie beschreibt die verschiedenen Klassifikationsverfahren, beginnend mit Naive Bayes, anschließend SVM und zuletzt SLDA. Außerdem behandelt es die Probleme einer Multi-Label Klassifikation und deren Lösungen und beschreibt die erforderlichen Messwerte für die Evaluation einer Multi-Label Klassifikation, sowie die benutzten Frameworks.

1. Einleitung

Es werden der verwendete Korpus und der Multi-Label Learner für den SLDA erklärt.

Anschließend widmet sie sich den Ergebnissen der verschiedenen Klassifikationsverfahren und zum Schluss werden die Ergebnisse noch einmal kurz zusammengefasst und ein kurzer Ausblick für zukünftige Arbeiten gegeben.

2. Grundlagen

Grundsätzlich kann man die verschiedenen Klassifikationsverfahren in drei Gruppen einteilen: Verfahren des überwachten Lernens (supervised learning), des unüberwachten Lernens (unsupervised learning) und des bestärkenden Lernens (reinforcement learning).[2]

Beim überwachten Lernen wird ein Algorithmus mit Paaren aus Ein- und Ausgaben trainiert, anhand derer er eine Funktion erstellt, um später in der Lage zu sein selbständig unbekannte Daten zu klassifizieren.

Beim unüberwachten Lernen versucht ein Algorithmus selbständig in den Eingabedaten Zusammenhänge zu finden ohne dabei Kenntnisse über Zielwerte zu haben und ohne durch die Umwelt beeinflusst zu werden.

Beim bestärkendem Lernen wird versucht einem Algorithmus durch Belohnung und Bestrafung etwas beizubringen. Hierbei wird dem Algorithmus gesagt, wann er richtig oder falsch ist, er weiß allerdings nicht warum.

Die Klassifikationsverfahren, die in dieser Arbeit Verwendung finden, gehören zu den Verfahren des überwachten Lernens. Diese können in zwei Gruppen geteilt werden, in Binäre und Multiclass. Zu den binären Klassifikationsverfahren zählen unter anderem Naive Bayes und SVM, zu den multiclass Verfahren SLDA.

Der grundlegende Unterschied zwischen beiden Gruppen ist die Anzahl der Labels die verarbeitet werden können. Die binären Verfahren können zwei und die Multiclass beliebig viele verarbeiten.

Bei binären Klassifikationsverfahren kann man die zwei Labels in den meisten Fällen als "gehört dazu" oder "gehört nicht dazu" bezeichnen. Somit versuchen diese Klassifikationsverfahren in der Trainingsmenge ausreichend Features zu finden, dass eine erfolgreiche Zuordnung für das eine Label erfolgt. Alle anderen werden dem Anderem zugeordnet. Für eine Multi-Label Klassifikation sind hier zwei Probleme zu lösen. Erstens, wie kann man mehr als nur zwei Labels klassifizieren und zweitens, wie kann man mehr als nur ein Label pro Dokument verarbeitet werden.

Bei den multiclass Klassifikationsverfahren ist das Erste der beiden Probleme gelöst, da die Verfahren bereits mehr als nur zwei Labels verarbeiten können. Somit

2. Grundlagen

muss lediglich das zweite Problem gelöst werden, wie mehr als nur ein Label pro Dokument verarbeitet werden kann.

Dabei besteht die Trainingsmenge aus den Paaren aus Ein- und Ausgaben zum trainieren des Algorithmus. Die Eingabedaten, die für die Berechnung der Funktion zur entsprechenden Klassifizierung genutzt werden, nennt man Features. Die Ausgaben sind die Labels. Ein Dokument ist dabei entweder ein einzelnes Paar aus Ein- und Ausgaben oder nur die Eingaben, wenn das Label für dieses bestimmt werden soll.

2.1. Klassifikationsverfahren

Im Falle von Texten sind die Featuremengen meist sehr groß, da alle Worte der Trainingsmenge berücksichtigt werden. Dadurch erhöht sich bei den meisten Methoden der Rechenaufwand erheblich. Die verschiedenen Klassifikationsverfahren gehen damit unterschiedlich um. Manche haben von sich aus Methoden um die für die Klassifikation erforderlichen Features gering zu halten, andere nicht. Durch Methoden der Computerlinguistik, wie Stemming, Stopwortentfernung usw. lässt sich die Featuremenge erheblich verringern (vgl. Abschnitt 2.3).

Im folgenden werden die verwendeten Klassifikationsverfahren näher erläutert.

2.1.1. Naive Bayes

Beim Naive Bayes-Klassifikator handelte es sich um ein einfaches probabilistisches Modell, das auf den Satz von Bayes beruht (Gleichung 2.1).

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (2.1)$$

Dabei wird voraus gesetzt, dass die einzelnen Features stochastisch Unabhängig von einander sind und jeweils nur von dem Label des Dokumentes abhängen. Obwohl dies meistens nicht der Fall ist, erzielt der Naive Bayes-Klassifikator in den meisten Fällen trotzdem gute Ergebnisse.[16]

Ein Naive Bayes-Klassifikator b ist eine Funktion $b = \mathbb{R}^f \rightarrow C$, die Vektoren aus dem f -dimensionalen reellwertigen Featureraum auf eine Menge von Labels C abbildet. Für den Naive Bayes-Klassifikator gilt dabei $p(C|f_1, \dots, f_n)$ für ein Dokument mit n Features. Mit Hilfe des Satzes von Bayes lässt sich dies umformen in $p(C|f_1, \dots, f_n) = \frac{p(f_1, \dots, f_n|C)p(C)}{p(f_1, \dots, f_n)}$, allgemein formuliert posterior = $\frac{\text{prior} \times \text{likelihood}}{\text{evidence}}$.

2. Grundlagen

Obwohl die Unabhängigkeitsannahme oft ungenau ist, hat der Naive Bayes-Klassifikator mehrere Eigenschaften, die ihn in der Praxis extrem nützlich machen. Vor allem die Entkopplung der durch das Label bedingten Featureverteilungen bedeutet, dass jede Verteilung unabhängig als eine eindimensionale Verteilung abgeschätzt werden kann. Dies verringert Probleme die sich durch die Anzahl der Features in den Datensätzen ergeben. In der Regel ist die Schätzung für das richtige Label nicht gut. Solange aber das Label eine höhere Wahrscheinlichkeit hat als alle Anderen, ist das Ergebnis trotzdem richtig. Dadurch ist der Naive Bayes-Klassifikator weitgehend robust und gravierende Mängel im zugrunde liegenden Modell können ignoriert werden.

In den meisten Fällen wird für ein Label die Annahme getroffen, dass die Features für dieses Label normal verteilt sind. Anstatt der Verwendung der Normalverteilung kann aber auch der Kerndichteschätzer (kernel density estimation) verwendet werden. Dabei handelt es sich um ein statistisches Verfahren zur Schätzung der Wahrscheinlichkeitsverteilung einer Zufallsvariable. Ebenfalls vielversprechend zur Dichteschätzung sind Methoden der automatischen Diskretisierung kontinuierlicher Funktionen.[6]

2.1.2. Support Vector Machine

Eine Support Vector Machine (SVM) ist ein sogenannter Large Margin Classifier, das heißt, dass beim trainieren versucht wird den Abstand der einzelnen Dokumente zur Trenngeraden so groß wie möglich zu wählen. Jedes Dokument wird dabei durch einen Vektor in einem Vektorraum repräsentiert. Die SVM versucht im Trainingsschritt eine Hyperebene in den Vektorraum zu legen, um die Trainingsdokumente voneinander zu trennen. Dabei wird versucht den Abstand der nächstliegenden Trainingsvektoren zur Hyperebene größtmöglich zu wählen, um später zu erreichen, dass Dokumente, die wenig den Trainingsdokumenten entsprechen, möglichst zuverlässig klassifiziert werden.

Beim Berechnen der Hyperebene werden dabei nur die Trainingsdokumente beachtet, deren Vektoren nah an der Hyperebene liegen. Diese Vektoren reichen aus um die Hyperebene mathematisch zu beschreiben, sie werden auch Stützvektoren genannt, deshalb auch der Name Support Vector Machine. Durch diese Einschränkung kann es zu einer erheblichen Zeitersparnis beim Training kommen.

Voraussetzung für eine erfolgreiche Berechnung der Hyperebene ist, dass die Trainingsdokumente linear trennbar sind, weil die Hyperebene nicht "verbogen" werden kann. In den meisten Anwendungsfällen ist dies nicht der Fall, weshalb die SVM im Fall nicht linear trennbarer Dokumente den sogenannten Kernel-Trick verwendet um eine lineare Trennung zu erreichen. Die grundlegende Idee des Kernel-Trick ist den Vektorraum und die darin befindlichen Vektoren in einen höherdimensionalen

2. Grundlagen

Raum zu überführen. In einem genügend hohem Raum wird die Vektormenge linear trennbar, im Zweifelsfall in einem Vektorraum mit unendlicher Dimension.

Die Hochtransformationen sind enorm rechenintensiv während die Darstellung der Hyperebene im niedrigdimensionalen Raum sehr komplex und im Allgemeinen unbrauchbar ist. Hier kommt der Kernel-Trick ins Spiel. Wird die Hyperebene durch eine geeignete Kernelfunktion beschrieben, die im Hochdimensionalen die Hyperebenen beschreibt und im Niedrigdimensionalen nicht zu komplex ist, können die Transformationen umgesetzt werden ohne sie rechnerisch tatsächlich ausführen zu müssen. Die Kernelfunktion betrachtet für die Transformationen lediglich die Stützvektoren, da diese ausreichen um die Hyperebene darzustellen.[11]

Es gibt noch weitere Verfahren um SVMs flexibler zu gestalten. Dazu gehören zum Beispiel Methoden die die Menge der Stützvektoren verringern oder die das Overfitting vermeiden. Eine weit verbreitete Methode um das Training der SVM einfacher zu gestalten ist Sequential Minimal Optimization(SMO). Beim SMO handelt es sich um einen Algorithmus zum effizienten Lösen eines quadratischen Optimierungsproblem, welches beim Trainieren einer SVM auftritt. SMO ist ein iterativer Algorithmus, der dieses Optimierungsproblem berechnet, indem er es in eine Reihe kleinerer Probleme aufteilt und diese anschließend analytisch löst.[7]

2.1.3. Supervised Latent Dirichlet Allocation

Beim Supervised Latent Dirichlet Allocation (SLDA) handelt es sich um eine Erweiterung der Latent Dirichlet Allocation (LDA), weshalb der SLDA für das überwachte Lernen benutzt werden kann.

Die Grundlage für SLDA/LDA ist das Topic Modell, ein statistisches Modell, bei der ein Dokument (Text, Bild, usw.) als Sammlung von verschiedenen "Topics" betrachtet wird. Dabei wird erwartet, dass in einem Dokument eines bestimmten Topics Worte, die für dieses speziell sind, häufiger vorkommen, als Worte für andere Topics. Worte die unabhängig von Topics auftreten, kommen dabei meistens in allen Dokumenten gleich häufig vor. So kommen zum Beispiel in Dokumenten zum Thema Hunde Worte wie "Hund" oder "Knochen" häufiger vor, in Dokumenten zum Thema Katzen hingegen Worte wie "Katze" oder "Maus". Worte wie "und" oder "ist" kommen in beiden ungefähr gleich häufig vor. Da ein Dokument in der Regel mehr als ein Thema beinhaltet, erwartet man, dass in einem Text der zu 90% über Hunde und zu 10% über Katzen ist, die Worte der entsprechenden Themen in einem Verhältnis von 9 : 1 vorkommen.

Beim LDA handelt es sich um ein generatives Wahrscheinlichkeitsmodell. Hierbei wird jedes Dokument als eine Mischung verschiedener Themen (latent topics), deren Anzahl zu Beginn festgelegt wird, betrachtet. Jedes Wort eines Dokumentes gehört

2. Grundlagen

ebenfalls zu einem oder mehreren Themen. Die Themen stellen dabei die Beziehung zwischen den Dokumenten dar. Jedes Dokument ist charakterisierbar als eine Menge von Topics, dies entspricht den Standardannahmen des Bag-of-Words Modells. Dadurch sind die einzelnen Worte austauschbar.[3]

Beim generativen Prozess wird ein Dokument als eine zufällige Mischung der latenten Topics repräsentiert und jedes Topic als eine Verteilung über den Worten charakterisiert. Für ein Dokument i im Korpus D ist er wie folgt definiert:

1. Wähle $\theta_i \sim \text{Dir}(\alpha)$, $\text{Dir}(\alpha)$ ist die Dirichlet-Verteilung für den Parameter α
2. Wähle $\phi_k \sim \text{Dir}(\beta)$, $k \in 1, \dots, K$
3. Für jedes Wort $w_{i,j}$, $j \in 1, \dots, N_i$
 - a) Wähle Thema $z_{i,j} \sim \text{Multinomial}(\theta_i)$
 - b) Wähle Wort $w_{i,j} \sim \text{Multinomial}(\phi_{z_{i,j}})$

Beim SLDA handelt es sich um eine Erweiterung des LDA, damit er für überwachtes Lernen benutzt werden kann. Es wird für jedes Dokument eine Antwortvariable hinzugefügt. Hierbei ist es vollkommen egal, was genau die Antwortvariable repräsentiert, die Sterne einer Bewertung oder das Thema eines Dokumentes. Die Dokumente werden gemeinsam mit den Antwortvariablen modelliert, um latente Topics zu finden, damit für künftige unbekannte Dokumente die besten Vorhersagen getroffen werden können. Der generative Process:

1. Ziehe Themenverteilung $\theta|\alpha \sim \text{Dir}(\alpha)$.
2. Für jedes Wort
 - a) Ziehe Themenzuordnung $z_n|\theta \sim \text{Mult}(\theta)$.
 - b) Ziehe Worte $w_n|z_n, \beta_{1:K} \sim \text{Mult}(\beta_{z_n})$
3. Ziehe Antwortvariable $y|z_{1:N}, \eta, \sigma^2 \sim \text{N}(\eta^T \bar{z}, \sigma^2)$ für $y \in \mathbb{R}$

In Abbildung 2.1 ist eine grafische Repräsentation des SLDA dargestellt. Die weißen Kreise sind die latenten Variablen, die grauen die Messgrößen. Y_d ist ein Label für das Dokument $d \in D$ und $W_{d,n}$ ist das Wort $n \in N$ für das Dokument $d \in D$. α ist der Parameter für die Dirichletverteilung, θ_d ist der Topicanteil für das Dokument $d \in D$, $Z_{d,n}$ ist der Topicanteil für das Wort $n \in N$ und das Dokument $d \in D$, $\beta_{1:K}$ sind die Topics und η, σ^2 sind die Antwortparameter.

Für ein Dokument und dessen Antwort ergibt sich die A-posteriori-Wahrscheinlichkeit der latenten Variablen wie in Abbildung 2.2. Weil dies nicht effizient berechenbar ist, werden Variationsmethoden zur Approximation der A-posteriori-Wahrscheinlichkeit angewandt.

2. Grundlagen




Abbildung 2.1.: Grafische Darstellung des SLDA

$$p(\theta, z_{1:N} | w_{1:N}, y, \alpha, \beta_{1:K}, \eta, \sigma^2) = \frac{p(\theta | \alpha) \left(\prod_{n=1}^N p(z_n | \theta) p(w_n | z_n, \beta_{1:K}) \right) p(y | z_{1:N}, \eta, \sigma^2)}{\int d\theta p(\theta | \alpha) \sum_{z_{1:N}} \left(\prod_{n=1}^N p(z_n | \theta) p(w_n | z_n, \beta_{1:K}) \right) p(y | z_{1:N}, \eta, \sigma^2)}$$

Abbildung 2.2.: A-posteriori-Wahrscheinlichkeit der latenten Variablen für SLDA

Implementierung

Da bisher nur eine Implementierung des SLDA in C++ existiert und die verwendeten Frameworks (vgl. Abschnitt 2.4) eine Implementierung in Java benötigen, musste diese erfolgen. Die C++-Implementierung, auf der die Java-Implementierung basiert, stammt von Chong Wang¹ bei Github². Neben den nötigen Anpassungen für Java und Weka ist die größte Anpassung der BFGS-Optimierer. So benutzt die C++-Implementierung einen Minimierer, die Java hingegen einen Maximierer.

Der C++-SLDA liefert keine Wahrscheinlichkeiten für die Labels, sondern einen Score, der nicht gut vergleichbar ist. Im Java-SLDA wird der Score noch einmal durch die Anzahl der trainierten Labels geteilt, damit vergleichbare Werte herauskommen. Dadurch sind die Werte meistens relativ klein, was sich in dem niedrigen Schwellwert für den Topic Modell Multi-Label Learner widerspiegelt (vgl. Kapitel 4).

Um zu prüfen, ob die Java-Implementierung funktioniert, wurde für einen Testda-

¹<https://www.cs.cmu.edu/~chongw/>

²<https://github.com/danstowell/slida>

2. Grundlagen

tensatz³ ein Vergleich der beiden Implementierungen gemacht. Für diesen Testdatensatz klassifiziert der C++-SLDA 71,875%(575 von 800) richtig, der Java-SLDA 69,875%(559 von 800) richtig.[14]

Ähnliche Ansätze

Der SLDA ist nicht die einzige Erweiterung des LDA für das überwachte Lernen.

Von Daniel Ramage stammt der Ansatz des Labeled LDA. Dabei handelt es sich um eine eins-zu-eins Beziehung zwischen den latenten Topics des LDA und den Labels. Die Labels beeinflussen dabei θ_d und nicht $Z_{d,n}$ wie beim SLDA, das heißt die vom LDA benutzten Topics sind die, die durch die Labels vorgegeben wurden.[8]

Von Timothy Rubin stammen die Ansätze des Flat-, Prior- und Dependency-LDA.[9]

Der Flat-LDA unterscheidet sich zum Labeled LDA lediglich dadurch, dass beim Flat-LDA die Labels nicht durch eine latente Variable beeinflusst werden.

Beim Prior-LDA werden die relativen Häufigkeiten für ein Label im Trainingskorpus ebenfalls modelliert, damit wird Rechnung für die verschiedenen beobachteten Labelhäufigkeiten getragen. Dies wird durch einen zweistufigen generativen Prozess für jedes Dokument erreicht. Zuerst wird eine Reihe von beobachteten Labels aus einer korpusweiten Multinomialverteilung entnommen und im zweiten Prozess werden unter diesen Labels die Worte für das Dokument erzeugt.

Beim Dependency-LDA werden, wie der Name schon andeutet, die Abhängigkeiten zwischen den Labels zusätzlich modelliert. Hier gibt es mehrere korpusweite Verteilungen aus denen die Labels für ein Dokument berechnet werden.

2.2. Multi-Label Klassifikation

Für eine Multi-Label Klassifikation gibt es verschiedene Ansätze, die in zwei Gruppen geteilt werden können. Zum einen gibt es die Problemtransformationen, zum anderen die Algorithmusadaptionen. Die verschiedenen Problemtransformationen werden im nachfolgendem Abschnitt 2.2.1 betrachtet.

Zu den Algorithmusadaptionen gehören unter anderem das Dirichlet-Bernoulli Alignment (DBA).[15]

³<https://www.cs.cmu.edu/~chongw/slida/>

2. Grundlagen

Beim DBA handelt es sich um eine Weiterentwicklung des LDA für die Multi-Label Klassifikation. DBA geht von einer Baumstruktur der Daten aus, jedes Multi-Labeled Dokument wird als Menge von Single-Labeled Dokumenten betrachtet.

2.2.1. Problemtransformationen

Wie bereits oben beschrieben gibt es für die binären Klassifikationsverfahren zwei Probleme zu lösen und eines für die multiclass Klassifikationsverfahren.

Ein weit verbreiteter Ansatz für binäre Klassifikationsverfahren um eine multiclass Klassifikation zu erreichen ist der one-vs-all (one-vs-rest) Ansatz. Bei diesem Ansatz wird für jedes Label in der Trainingsmenge ein Klassifizierer trainiert. Sollen zum Beispiel fünf verschiedene Labels klassifiziert werden, müssen fünf Klassifikatoren trainiert werden. Dieser Ansatz löst allerdings nicht das zweite Problem.

Um das zweite Problem, dass ein einzelnes Dokument mehr als nur ein Label besitzt, zu lösen, muss eine Transformation des Korpus bzw. der Dokumente/der Labelmenge erfolgen. Die erste und einfachste Transformation ist jedes zu trainierende Dokument so oft zu kopieren, wie es verschiedene Labels hat und auf dieser Menge das Training durchzuführen. Diese Möglichkeit hat mehrere Nachteile. Zum einen werden so keine Beziehungen zwischen den Labels berücksichtigt und zum anderen ist der Rechenaufwand erheblich höher. Bei einem Trainingskorpus von 100 Dokumenten mit durchschnittlich 3 Labels wären dies etwa 300 Dokumente auf denen trainiert werden müsste. Eine Erweiterung davon ist die Einführung von Gewichten. Dabei wird zwar berücksichtigt, dass es Beziehungen zwischen den Labels geben kann, allerdings werden diese nur unzureichend modelliert.[12]

Es gibt noch weitere einfache Transformationen: select-max, select-min, select-random und ignore. Bei diesen werden die Labelmengen auf jeweils ein Label reduziert bzw. im Falle von ignore werden alle Dokumente, die mehr als ein Label haben, ignoriert. Der Nachteil dieser Methoden ist der Verlust von Informationen. Der Vorteil dieser Methoden besteht darin eine Klassifikation ohne weiteren Aufwand mit den binären Klassifikationsverfahren durchführen zu können.

Beim Label Powerset handelt es sich um eine einfache und effektive Transformationsmethode. Für jede vorkommende Labelkombination wird ein neues Label eingeführt, alle Dokumente mit den Labels $\lambda_1, \lambda_3, \lambda_4$ bekommen also das neue Label $\lambda_{1,3,4}$. Mittels dieser Transformation kann ein binäres Klassifikationsverfahren trainiert werden und gibt statt einem Label eine Menge von Labels an. Liefert das binäre Klassifikationsverfahren eine Wahrscheinlichkeitsverteilung für alle Klassen,

2. Grundlagen

ist es möglich mittels des Label Powersets die Wahrscheinlichkeit der einzelnen Labels zu berechnen und so auch unbekannte Kombinationen zu klassifizieren.

Der Rechenaufwand für Label Powerset bezüglich der Anzahl an Labels hängt von der Komplexität der Basisklassifikatoren hinsichtlich der Anzahl an Labels ab. Die Zahl der zu trainierenden Modelle ist nach oben durch $\min(m, 2^q)$ beschränkt, m Anzahl an Trainingsdaten und q Anzahl an unterschiedlichen Labels. In der Regel ist die Zahl jedoch wesentlich kleiner, trotzdem stellt es für große Werte für m, q ein erhebliches Komplexitätsproblem dar.

Eine Verbesserung der Label Powerset Methode ist die random k-labelsets Methode (RAkEL). RAkEL erstellt ein Ensemble von Label Powerset Klassifikatoren. Jeder Label Powerset Klassifikator wird unter Verwendung einer kleinen aber unterschiedlichen und zufälligen Teilmenge der Labels trainiert. Auf diese Weise schafft RAkEL es Labelkorrelationen zu berücksichtigen, bei gleichzeitiger Vermeidung der Label Powerset Probleme.[13]

Beim SLDA handelt es sich um ein Topic Modell und somit um ein multiclass Klassifikationsverfahren. Aus diesem Grund muss für eine Multi-Label Klassifikation ein anderes Modell gewählt werden, weil RAkEL oder auch Label Powerset jeweils nur für binäre Klassifikationsverfahren funktioniert. Mulan (vgl. Abschnitt 2.4) verfügt über keinen Multi-Label Learner für Topic Modelle, daher muss hier ein eigener Ansatz verfolgt werden. Dieser ist ausführlich im Kapitel 4 beschrieben.

2.2.2. Evaluation

Die Evaluation von Multi-Label Klassifikationen benötigt andere Maße als die von herkömmlichen Klassifikationen. Dabei werden zwei verschiedene Methoden zur Berechnung herangezogen. Zum einen die Bipartitionen zum anderen Ranglisten in Bezug auf die zugrunde liegenden Multi-Label Daten.

Die Bipartitionen bestehen aus den Zahlwerten für true positive(tp), true negative(tn), false positive(fp) und false negative(fn). Hiermit werden nun Werte für Precision(Gleichung 2.2), Recall(Gleichung 2.3) und F_1 -Measure(Gleichung 2.4) bestimmt.

$Y_i \subseteq L$ ist die Menge der wahren Labels aus der gesamten Menge aller Labels L für ein Dokument i , und Z_i die Vorhergesagten.

Es wird dabei unterschieden zwischen Example-Based, Micro-averaged und Macro-averaged.

2. Grundlagen

$$\text{Precision} = \frac{1}{m} \sum_{i=1}^m \frac{|Y_i \cap Z_i|}{|Z_i|} \quad (2.2)$$

$$\text{Recall} = \frac{1}{m} \sum_{i=1}^m \frac{|Y_i \cap Z_i|}{|Y_i|} \quad (2.3)$$

$$F_1\text{-Measure} = \frac{1}{m} \sum_{i=1}^m \frac{2|Y_i \cap Z_i|}{|Z_i| + |Y_i|} \quad (2.4)$$

Bei den Example-based Werten wird auf Grundlage der Bipartitionen die durchschnittliche Differenz zwischen den tatsächlichen und den vorhergesagten Labelmen gen berechnet.

Bei den Micro- und Macro-averaged Werten wird die Evaluierung für jedes Label einzeln vorgenommen und anschließend über alle Labels der Mittelwert gebildet. Diese nennt man auch Label-based Evaluationsmaße.

Der Unterschied zwischen Micro-averaged und Macro-averaged ist die Aufsum mierung der Werte. Die Grundstruktur für die Macro-averaged Werte ist in der Gleichung 2.5, für die Micro-averaged in Gleichung 2.6 beschrieben. Beim Micro-averaged wird zuerst die Summen gebildet und anschließend Precision, Recall usw. berechnet, beim Macro-averaged hingegen werden zuerst Precision, Recall usw. berechnet und anschließend die Summe gebildet. Bei Micro-averaged Werten hat man eine Gleichgewichtung der Dokumente, wo hingegen Macro-averaged eine Gleichgewichtung für die Labels liefert.[5]

$$B_{macro} = \frac{1}{q} \sum_{\lambda=1}^q B(tp_{\lambda}, fp_{\lambda}, tn_{\lambda}, fn_{\lambda}) \quad (2.5)$$

$$B_{micro} = B \left(\sum_{\lambda=1}^q tp_{\lambda}, \sum_{\lambda=1}^q fp_{\lambda}, \sum_{\lambda=1}^q tn_{\lambda}, \sum_{\lambda=1}^q fn_{\lambda} \right) \quad (2.6)$$

Für die Ranglisten basierten Evaluationsmaße lassen sich die folgenden Messwerte bestimmen. Der 1-Error wertet aus, wie häufig die am höchsten bewerteten Labels nicht in den relevanten Labels enthalten sind. Beim Coverage (Abdeckung) wird bestimmt, wie weit im Durchschnitt in der Rangliste der Labels nach unten gegangen werden muss, um alle relevanten Labels des Dokumentes zu erhalten. Das R-Loss(Ranking Loss) drückt die Anzahl der Male aus, bei denen irrelevante Labels höher sortiert werden als Relevante. Die Average Precision wertet den durchschnittlichen Anteil von Labels über einem bestimmten Label $\lambda \in Y_i$ aus, das tatsächlich in Y_i ist.

2. Grundlagen

Für den 1-Error und R-Loss sind somit jeweils kleine Werte gut, für die Average Precision Hohe. Beim Coverage muss jeweils ein Vergleich mit der Maximalanzahl von Labels pro Dokument und dem Durchschnitt erfolgen, um eine Ausgabe über dessen Güte machen zu können.

2.3. Preprocessing

Als Preprocessing werden alle Schritte bezeichnet die aus den eigentlichen Eingaben Werte machen, mit denen die Klassifikationsverfahren umgehen können. Da diese mathematische Methoden sind und als solche Zahlen und keine Texte bzw. Worte, wie im vorliegendem Fall, verarbeiten können, ist das Preprocessing ein wichtiger Bestandteil einer erfolgreichen Klassifizierung.

Für die Umwandlung in Zahlen gibt es verschiedene Methoden, da Naive Bayes und SLDA jeweils die Häufigkeit eines Features benötigen, ist die erste Methode offensichtlich, die Wortanzahl. Hierfür wird in jedem Dokument für jedes Wort die Häufigkeit gezählt.

Die SVM verwendet tf-idf Werte. Dabei steht tf-idf für Termfrequenz-inverse Dokumentenfrequenz (term frequency–inverse document frequency), für ein Wort i im Dokument j ergibt sich folgender tf-idf Wert $w_{i,j} = tf_{i,j} \cdot idf_i = tf_{i,j} \cdot \log \frac{N}{n_i}$, mit N Anzahl an Dokumenten und n_i Zahl der Dokumente, die i enthalten.[1]

Neben der Umwandlung der Texte in Zahlenwerte gibt es noch Methoden der Computerlinguistik um die Anzahl an Features zu reduzieren bzw. um weitere Features hinzuzufügen. Das meist genutzte Verfahren ist die Tokenisierung. Hierbei werden aus einem Fließtext die einzelnen Worte extrahiert. Der Text wird an Leer- und Interpunktionszeichen zerlegt. Ohne eine Tokenisierung würde der gesamte Text als ein einziges Feature betrachtet werden, was für eine Klassifikation in den meisten Fällen ungeeignet ist.

Ein weiteres Verfahren ist die Stoppwortentfernung, hier werden alle Stoppworte einer Sprache entfernt. Zu den Stoppworten zählen Artikel, Konjunktionen, Präpositionen und Negationen.

Beim Stemming oder Stammformreduktion, werden alle morphologische Varianten eines Wortes auf ihren gemeinsamen Wortstamm zurückgeführt. Die dafür genutzten Verfahren variieren zwischen einfachen regelbasierten Ansätzen bis hinzu komplexen linguistischen Methoden. Es erfolgt dabei nicht immer eine Reduktion auf den grammatikalischen Wortstamm. Es können je nach Ansatz vollkommen unterschiedliche

2. Grundlagen

Worte auf den gleichen Stamm reduziert werden. So können zum Beispiel die Worte "Wetter" und "Wetten" auf den Stamm "Wett" reduziert werden.

Das nächste Verfahren ist die Transformation in Groß- oder Kleinbuchstaben. Für das Englische mag diese Transformation auch einen sprachlichen Sinn haben. In den meisten Fällen erfolgt sie jedoch zur Featurereduktion.

Das letzte Verfahren, das hier erwähnt werden soll, ist die N-Gramm-Generierung. Dabei werden in der Regel Bi- bzw. Trigramme zusätzlich zu den Unigrammen erzeugt. Bei der N-Gramm-Generierung werden benachbarte Worte zu neuen Features zusammengefasst. Bei einem Unigramm handelt es sich somit um ein einzelnes Wort, bei Bigrammen um Wortpaare und bei Trigrammen um Worttriple. Für die Klassifikation werden in der Regel von den Unigrammen aufwärts N-Gramm-Gruppen hinzugefügt, das heißt für eine Klassifikation werden entweder nur Unigramme oder Uni- und Bigramm oder Uni-, Bi- und Trigramme verwendet. Durch die N-Gramm-Generierung erhöht sich die Anzahl der Features erheblich und somit unweigerlich die Rechenzeit für das Training. Eine N-Gramm-Generierung wird in der Regel gemacht, um für eine Klassifizierung nicht nur einzelne Worte, sondern auch Wortgruppen zu betrachten. Man verspricht sich dadurch eine höhere Erfolgsrate für eine Klassifikation.[4]

2.4. Frameworks

Für die oben beschriebenen Methoden der Multi-Label Klassifikation gibt es das Java-Framework Mulan, das viele dieser Methoden implementiert hat. Mulan verfügt dabei nicht über eigene Klassifikationsverfahren, sondern benutzt Weka.

Weka ist eine Sammlung von Algorithmen des maschinellen Lernens, unter anderem gehören dazu Naive Bayes und SMO, der oben beschriebene Algorithmus zum einfachen Trainieren der SVM (vgl. Abschnitt 2.1.2).

Mulan benutzt für die Eingabe das ARFF⁴-Format, welches auch Weka benutzt. Es stellt dabei bestimmte Anforderungen, jeder Datensatz muss für alle Labelattribute entweder den Wert 1 oder 0 haben. Die Labelattribute müssen zusätzlich noch einmal separat in einer xml-Datei stehen. Diese kann genutzt werden um Labelhierarchien darzustellen.

Mulan hat unter anderem die oben beschriebenen Label Powerset und RAkEL Methoden implementiert. Um einen RAkEL Multi-Label Learner zu erstellen muss

⁴<http://weka.wikispaces.com/ARFF+%28stable+version%29>

2. Grundlagen

allerdings ein anderer Multi-Label Learner mit angegeben werden, in den meisten Fällen ist das Label Powerset.

Auch für die Evaluation hat Mulan Klassen. So können beliebige Kreuzvalidierungen durchgeführt werden. Diese liefern die oben beschriebenen Evaluationsmaße.

Bei einer Kreuzvalidierung wird der Korpus in die angegebene Anzahl an Teilmengen gegliedert und anschließend erfolgen die Validierungen. Dabei wird jede Teilmenge einmal als Testmenge verwendet, die anderen Teilmengen werden zusammen als Trainingsmenge genommen. Bei einer 10-fach Kreuzvalidierung wird der Korpus somit in 10 Teile geteilt, anschließend werden 10 Validierungen mit jedem Teil als Testmenge durchgeführt. Die Ergebnisse jeder Validierung werden am Ende gemittelt.

3. Korpus

Der dieser Arbeit zugrunde liegende Korpus ist der Reuters-21578⁵ Korpus. Insgesamt enthält der Korpus 21578 Dokumente, englische Texte. Davon haben allerdings nur 11367 mindestens ein Label. Insgesamt gibt es 120 verschiedene Labels.

In einem ersten Schritt sind alle Labels, die in weniger als 1% der Dokumente vorkommen, entfernt worden. Das heißt jedes Label muss mindestens in 113 Dokumenten vorkommen. Danach sind noch 22 Labels vorhanden. Anschließend wurden alle Dokumente entfernt, die entweder kein oder nur ein Label haben.

Für die Klassifikation wurden zwei verschiedene Korpus erstellt. Im ersten Korpus wurden alle Dokumente mit mehr als 3 Labels und weniger als 2 Labels entfernt. Der somit verbleibende Korpus hat 1311 Dokumente mit 13268 Features. Davon haben 1140 Dokumente zwei Labels und 171 drei Labels. Im Durchschnitt hat ein Dokument 2,13 Labels. An der Gesamtzahl der Labels haben diese Einschränkungen nichts geändert, es sind insgesamt immer noch 22 Labels. Der Korpus hat insgesamt 108 verschiedene Labelsets, die zwischen einer Häufigkeit von 1 und 185 variieren.

Der zweiten Korpus enthält auch alle Dokumente die 4 Labels haben. Dadurch sind 53 Dokumente hinzugekommen, somit sind insgesamt 1364 Dokumente mit 13656 Features vorhanden. Im Durchschnitt hat hier jedes Dokument 2,20 Labels. Die Anzahl der Labelsets ist um 24 auf insgesamt 132 gestiegen.

Zur besseren Unterscheidung der beiden Korpus wird der erste Korpus, der alle Dokumente mit jeweils zwei oder drei Labels enthält, als *Korpus A* bezeichnet. Der andere Korpus, der Dokumente mit zwei, drei oder vier Labels enthält, als *Korpus B*.

Für die Umwandlung in das ARFF-Format mit den entsprechenden Transformationen für die Klassifikationsverfahren (Wortanzahl für Naive Bayes und SLDA und tf-idf für SVM) wurde der von Weka bereitgestellte Filter `StringToWordVector` benutzt.

Die Optionen, die jeweils benutzt wurden, sind in den Abbildungen 3.1 und 3.2 zu sehen.

3. Korpus

```
-P _ -W 2147483647 -prune-rate 0.0 -C -N 0 -L -stemmer weka
.core.stemmers.NullStemmer -M 0 -tokenizer weka.core.
tokenizers.WordTokenizer -delimiters " \r\n\t.,;:\'\"()
?!"
```

Abbildung 3.1.: `StringToWordVector` Optionen für Wortanzahl

```
-P _ -W 2147483647 -prune-rate 0.0 -T -I -N 0 -L -stemmer
weka.core.stemmers.NullStemmer -M 0 -tokenizer weka.core
.tokenizers.WordTokenizer -delimiters " \r\n\t.,;:\'\"()
?!"
```

Abbildung 3.2.: `StringToWordVector` Optionen für tf-idf

Die Option `-P _` gibt an, dass alle Attributnamen mit einem `_` anfangen sollen. Dies ist von Nöten, da es kein Attribut mit dem Namen `class` geben darf, weil diese Bezeichnung für das Label reserviert ist.

`-W 2147483647` gibt an, dass die ersten 2147483647 Features genommen werden sollen. Der Wert ist dabei der größtmögliche Integerwert.

`prune-rate 0.0` gibt an, dass kein Pruning statt finden soll.

`-C` gibt die Wortanzahl aus, `-I -N` die tf-idf Werte und `-N 0`, das keine Normalisierung statt finden soll.

`-L` wandelt alles in Kleinbuchstaben um.

`-stemmer weka.core.stemmers.NullStemmer` gibt an, das kein Stemming erfolgen soll.

Durch `-M 0` wird die minimale Termfrequenz auf 0 gesetzt und `-tokenizer weka.core.tokenizers.WordTokenizer` setzt den Tokenisierer mit den entsprechenden Optionen.

Nach der Filterung werden die Labelattribute entsprechend gesetzt und die ARFF-Datei und die xml-Datei gespeichert. In Abbildung 3.3 ist ein Dokument im ARFF-Format zu sehen. Der erste Werte jeden Paares ist der Index des Attributes und der zweite der Wert, in diesem Fall die Wortanzahl. Die Paare sind durch Kommata getrennt.

Von den im Abschnitt 2.3 Preprocessing beschriebenen Preprocessingmethoden wurden die Tokenisierung, die Transformation in Kleinbuchstaben und die Umwandlung in die Wortanzahl für die Korpus für Naive Bayes und SLDA bzw. die Umwandlung in tf-idf Werte für die Korpus für SVM verwendet.

⁵<http://modnlp.berlios.de/reuters21578.html>

3. Korpus

```
{0 1,1 1,28 1,116 1,170 5,234 1,253 1,295 1,326 1,341 1,361
1,367 1,435 3,437 7,448 1,536 1,585 1,594 1,609 1,617 4,654
1,716 1,734 2,780 1,823 1,835 2,855 1,894 1,963 1,994 2,1008
1,1046 2,1070 1,1144 1,1163 1,1179 1,1200 1,1277 3,1325
1,1343 1,1549 1,1553 4,1585 2,1630 1,1692 1,1778 2,1780
1,1788 1,1853 1,1910 1,1927 1,1998 13,2027 1,2057 1,2140
1,2142 1,2266 4,2305 1,2484 6,2526 1,2544 1,2645 5,2930
1,2993 2,3037 1,3209 2,3235 1,3242 1,3355 1,3360 1,3374
1,3485 1,3486 1,3579 1,3792 2,3897 2,3957 3,4410 1,4472
1,4545 1,4562 6,4591 1,4630 2,4690 3,4757 2,4833 1,4935
3,5090 1,5180 1,5181 2,5204 1,5221 1,5343 1,5406 1,5431
3,5435 9,5476 2,5477 1,5640 1,5663 3,5715 1,5722 2,5790
15,5846 1,5857 1,5880 6,6038 1,6176 2,6186 1,6210 1,6402
1,6593 2,6594 1,6680 1,6681 1,6686 13,6708 1,6709 1,6735
1,6743 1,6745 1,6958 1,7004 1,7023 3,7030 3,7052 1,7146
1,7153 1,7317 1,7348 1,7357 3,7375 1,7498 1,7499 3,7562
2,7649 1,7759 1,7818 1,7820 1,7849 2,7889 1,7909 3,8055
2,8106 1,8164 11,8226 2,8261 1,8291 1,8373 3,8399 1,8446
2,8568 1,8671 21,8699 1,8702 6,8710 1,8736 2,8783 4,8808
1,8851 4,8951 1,9045 1,9097 5,9130 2,9163 1,9164 2,9303
6,9564 3,9627 1,9718 2,9821 2,9945 1,9993 1,10067 1,10123
1,10124 1,10267 1,10302 3,10303 1,10317 1,10354 11,10420
1,10427 1,10429 1,10458 1,10647 5,10667 5,10678 2,10924
1,11069 2,11183 1,11268 2,11387 1,11535 3,12002 2,12094
2,12104 1,12108 1,12111 25,12112 1,12113 1,12127 2,12128
1,12224 14,12262 1,12283 3,12395 6,12473 3,12501 1,12518
1,12596 1,12726 1,12731 10,12732 1,12953 2,13023 1,13050
2,13054 2,13222 2,13246 1,13273 1}
```

Abbildung 3.3.: Beispiel eines Dokumentes im ARFF-Format

4. Topic Modell Multi-Label Learner

Da das Mulan-Framework über keinen Multi-Label Learner verfügt, der die speziellen Eigenschaften eines Topic Modells berücksichtigt, musste dieser entwickelt werden. Im Folgendem werden die grundlegende Idee sowie die wichtigsten Punkte der konkreten Umsetzung beschrieben.

Da es sich bei Topic Modellen im Allgemeinen und beim SLDA im Speziellen um ein multiclass Klassifikationsverfahren handelt, die somit zugrunde liegenden Klassifikationsverfahren eine beliebige Anzahl an verschiedenen Labels unterstützen, musste lediglich eine Möglichkeit gefunden werden, wie eine Vorhersage für mehrere Labels pro Dokument erfolgen kann. Die Idee war, für jedes Label eines Dokumentes ein anderes Topic Modell zu trainieren. Wenn zum Beispiel ein Dokument drei Labels hat werden also drei Topic Modelle trainiert.

Im Trainingsschritt wird zuerst die maximale Zahl an Labels pro Dokument bestimmt, damit die Anzahl der zu trainierenden Topic Modelle bestimmt werden kann. Hat ein Trainingskorpus zum Beispiel Dokumente mit ein, zwei oder drei Labels, werden drei verschiedene Topic Modelle trainiert, hat der Korpus hingegen nur Dokumente mit zwei und drei Labels werden nur zwei Topic Modelle trainiert.

Das erste Topic Modell wird mit allen Dokumenten und dem jeweils ersten Label trainiert. Jedes Weitere mit den Dokumenten und ihrem entsprechenden Label. Dokumente, die kein entsprechendes Label mehr haben, also Dokumente die weniger als die berechnete Maximalanzahl an Labels haben, werden nicht in die Trainingsmenge aufgenommen. Mit steigender Anzahl der Labels nimmt somit die Zahl der Trainingsdokumente ab, sofern nicht alle Dokumente die gleiche Anzahl an Labels besitzen. Im Beispiel von oben, wird das erste Modell mit allen Dokumenten und dem jeweils ersten Label trainiert. Die Trainingsmenge für das zweite Modell besteht aus den Dokumenten mit zwei oder drei Labels und jeweils dem zweiten Label und für das dritte Modell nur noch das den Dokumenten mit drei Labels.

Da das trainieren der Modelle sehr aufwändig in der Berechnung ist und Java jeweils nur einen Prozessor benutzen kann, ist der Multi-Label Learner so implementiert, dass jedes Modell gleichzeitig auf einem anderen Prozessor trainiert wird,

4. Topic Modell Multi-Label Learner

sofern die Anzahl der Prozessoren bzw. Modelle es erlaubt. Ansonsten können entsprechend weniger gleichzeitig trainiert.

Sollen nun die Labels für ein Dokument vorhergesagt werden, wird wie folgt vorgegangen. Zunächst wird eine Vorhersage von jedem trainierten Modell für das Dokument gemacht. Ist die Wahrscheinlichkeit für ein Label dabei oberhalb eines Schwellwerts wird das Dokument mit dem entsprechendem Label klassifiziert. Für die drei Modelle aus dem Beispiel oben werden für die ersten beiden Modelle jeweils ein Label mit Wahrscheinlichkeiten oberhalb des Schwellwerts berechnet, für das dritte Modell eine darunter. Somit wird das Dokument mit den ersten beiden Labels klassifiziert und nicht mit dem Dritten.

Um einen entsprechenden Schwellwert zu finden wurden einige 10-fach Kreuzvalidierungen durchgeführt. Die Ergebnisse für die Precisionwerte sind in Abbildung 4.1, für die Recallwerte in Abbildung 4.2 und für die F_1 -Measurewerte in Abbildung 4.3 zu finden. Die kompletten Evaluationsergebnisse für die einzelnen Schwellwerte sind in Anhang A aufgeführt.




Abbildung 4.1.: Precisionwerte für verschiedene Schwellwerte im Topic Modell Multi-Label Learner

Für die Precision ergibt sich ein recht eindeutiges Bild. Sowohl Example-Based, als auch Micro-averaged Precision haben den höchsten Wert bei einem Schwellwert von 0,11. Für die Macro-averaged Precision ergibt sich ein etwas höherer Wert bei einem Schwellwert von 0,1.

4. Topic Modell Multi-Label Learner




Abbildung 4.2.: Recallwerte für verschiedene Schwellwerte im Topic Modell Multi-Label Learner

Die Recallwerte für Example-Based und Micro-averaged schwanken kaum. Die Example-Based Recallwerte bewegen sich in einem Bereich von 0,0112, die Micro-averaged lediglich in einem Bereich von 0,0083. Beide haben jedoch ihren Höchstwert bei 0,12. Die Macro-averaged Recallwerte bewegen sich hingegen in einem Bereich von 0,0457 und haben ihren Höchstwert bei 0,13. Der Example-Based Recallwert ist am höchsten bei einem Schwellwert von 0,12, der Micro-averaged ebenfalls, der Macro-averaged Recallwert bei einem Schwellwert von 0,13.

Für die F_1 -Measurewerte ergibt sich ein ähnliches Bild wie für die Precisionwerte. Wie auch bei der Precision sind für Example-Based und Micro-averaged F_1 -Measure die Werte am höchsten bei einem Schwellwert von 0,11. Dies gilt auch für den Macro-averaged F_1 -Measurewert.

Für die Precision sind zwei der drei Werte bei einem Schwellwert von 0,11 am höchsten, der dritte bei 0,1, für die F_1 -Measurewerte haben alle drei den Höchstwert bei 0,11. Lediglich die Recallwerte haben bei 0,12 bzw. bei 0,13 ihre Höchstwerte. Dadurch ergibt sich ein eindeutiges Bild, das der beste Schwellwert bei 0,11 liegt. Aus diesem Grund ist der Schwellwert für die weiteren Berechnungen 0,11.

4. Topic Modell Multi-Label Learner




Abbildung 4.3.: F_1 -Measurewerte für verschiedene Schwellwerte im Topic Modell Multi-Label Learner

5. Ergebnisse

Zur Evaluierung werden die oben beschriebenen Methoden benutzt. Naive Bayes und SMO aus Weka jeweils mit RAKel und SLDA mit dem entwickeltem Topic Modell Multi-Label Learner. Die Ergebnisse stammen jeweils von einer 10-fach Kreuzvalidierung die mit Hilfe der Klassen des Mulan-Frameworks gemacht wurden. Im ersten Schritt sind die verschiedenen Algorithmen jeweils mit den Standardeinstellungen getestet worden. Anschließend wurden für Naive Bayes und SLDA weitere Kreuzvalidierungen mit unterschiedlichen Einstellungen durchgeführt. Verschiedene Tests mit unterschiedlichen Einstellungen für die SVM haben keine signifikanten Verbesserungen ergeben, weshalb diese nicht weiter ausgeführt werden. Die gesamte Liste der Evaluationswerte befinden sich in Anhang B.

Evaluationsmaße	Naive Bayes	SVM	SLDA
Example-Based Precision	0.6621	0.8947	0.6602
Example-Based Recall	0.8572	0.8460	0.7717
Example-Based F_1 -Measure	0.7194	0.8592	0.7004
Micro-averaged Precision	0.5792	0.9297	0.6361
Micro-averaged Recall	0.8485	0.8381	0.7620
Micro-averaged F_1 -Measure	0.6881	0.8813	0.6933
Macro-averaged Precision	0.5020	0.8421	0.5086
Macro-averaged Recall	0.7531	0.6734	0.5353
Macro-averaged F_1 -Measure	0.5761	0.7251	0.4924
Coverage	3.7505	3.4801	2.6889
1-Error	0.2441	0.0885	0.1724
R-Loss	0.0806	0.0638	0.0488
Average Precision	0.8011	0.8856	0.8343

Tabelle 5.1.: Ergebnisse der Kreuzvalidierung für Korpus A

Die Ergebnisse für den Korpus A (vgl. Kapitel 3) befinden sich in Tabelle 5.1. Die SVM liefert hierbei für die verschiedenen Precision- und F_1 -Measurewerte jeweils die höchsten Werte, die Recallwerte sind jeweils beim Naive Bayes am Höchsten. Bis auf die Recallwerte und den Macro-averaged F_1 -Measurewert liefern Naive Bayes und SLDA fast dieselben Werte für Precision und F_1 -Measure.

5. Ergebnisse

Für die Ranglistenmaße sieht das jeweils ganz anders aus. Der Korpus A hat maximal drei Labels pro Dokument, im Durchschnitt 2,13. Sowohl Naive Bayes und SVM haben für den Coverage jeweils Werte von über drei, nur der SLDA liegt darunter und hat somit für den Coverage den besten Wert. Ebenfalls für das R-Loss liefert der SLDA den besten Wert. Für den 1-Error und die Average Precision liefert wieder die SVM die besten Werte, allerdings ist hier der SLDA deutlich besser als der Naive Bayes.

Die Ergebnisse für den Korpus B sind der Tabelle 5.2 zu entnehmen. Die meisten Werte haben sich dabei nur geringfügig geändert. Lediglich die Werte für den SLDA haben sich in den meisten Fällen erheblich verschlechtert. Für die Example-Based Precision ist der Werte von 0,6602 auf 0,4888 gesunken. Für Coverage und R-Loss beim SLDA haben sich die Werte ebenfalls erheblich verschlechtert. Die SVM ist in den Precisionwerten fast gleich gut.

Evaluationsmaße	Naive Bayes	SVM	SLDA
Example-Based Precision	0.6506	0.8940	0.4888
Example-Based Recall	0.8664	0.8412	0.7866
Example-Based F_1 -Measure	0.7151	0.8547	0.5947
Micro-averaged Precision	0.5759	0.9243	0.4777
Micro-averaged Recall	0.8534	0.8279	0.7739
Micro-averaged F_1 -Measure	0.6872	0.8732	0.5907
Macro-averaged Precision	0.4967	0.8243	0.4876
Macro-averaged Recall	0.7648	0.6673	0.5896
Macro-averaged F_1 -Measure	0.5767	0.7156	0.4909
Coverage	3.7332	3.7009	3.1402
1-Error	0.2537	0.0880	0.3029
R-Loss	0.0779	0.0654	0.0623
Average Precision	0.7992	0.8840	0.7526

Tabelle 5.2.: Ergebnisse der Kreuzvalidierung für Korpus B

Die Tabelle 5.3 zeigt die Ergebnisse für Naive Bayes mit verschiedenen Optionen jeweils für beide Korpus. Die Optionen sind die jeweils die von Weka unterstützen. Bei der Option *D* wird überwachte Diskretisierung zur Verarbeitung numerischer Attribute verwendet. Bei der Option *K* wird ein Kerndichteschätzer anstatt der Normalverteilung für numerische Attribute verwendet.

Beide Varianten liefern für die Precisionwerte bessere Ergebnisse. Für Naive Bayes mit überwachter Diskretisierung sind auch jeweils Recall und F_1 -Measure besser. Mit dem Kerndichteschätzer sind die Recallwerte erheblich schlechter und somit

5. Ergebnisse

auch die Werte für F_1 -Measure. Für die Micro- und Macro-averaged Precision ist der Kerndichteschätzer besser.

Bei den Ranglistenmaßen liefert jeweils die überwachte Diskretisierung die besten Ergebnisse. Beim Coverage hat sich der Wert beim Kerndichteschätzer im Vergleich zu den Standardeinstellungen fast verdoppelt, von 3,7505 auf 6,6790 für Korpus A und von 3,7332 auf 6,8920 für Korpus B. Bei der überwachten Diskretisierung hat sich der Wert für die verschiedenen Korpus kaum verändert.

Insgesamt die besten Ergebnisse liefert der Naive Bayes mit überwachter Diskretisierung.

Evaluationsmaße	Korpus A			Korpus B		
	Standard	D	K	Standard	D	K
EB Precision	0.6621	0.7516	0.7014	0.6506	0.7369	0.7007
EB Recall	0.8572	0.8823	0.6073	0.8664	0.8833	0.5974
EB F_1 -Measure	0.7194	0.7907	0.6351	0.7151	0.7826	0.6271
Micro Precision	0.5792	0.7087	0.8377	0.5759	0.6965	0.8494
Micro Recall	0.8485	0.8794	0.5980	0.8534	0.8799	0.5808
Micro F_1 -Measure	0.6881	0.7846	0.6976	0.5767	0.7773	0.6896
Macro Precision	0.5020	0.6606	0.6815	0.4967	0.6608	0.7064
Macro Recall	0.7531	0.7740	0.3991	0.7648	0.7864	0.3921
Macro F_1 -Measure	0.5761	0.6795	0.4682	0.5767	0.6837	0.4702
Coverage	3.7505	2.8770	6.6790	3.7332	2.9247	6.8920
1-Error	0.2441	0.1518	0.2632	0.2537	0.1569	0.2580
R-Loss	0.0806	0.0503	0.1735	0.0779	0.0487	0.1767
Average Precision	0.8011	0.8717	0.7203	0.7992	0.8713	0.7168

Tabelle 5.3.: Ergebnisse der Kreuzvalidierung für Naive Bayes mit verschiedenen Einstellungen

Example-Based (EB), Micro-averaged (Micro) und Macro-averaged (Macro)

Im nächsten Schritt ist beim SLDA die Anzahl der Topics erhöht worden. Durch verschiedene Tests hat sich diese Option als die Vielversprechendste herausgestellt. Durch die Anzahl der Topics wird angegeben wie viele Worte pro Label zur Klassifikation benutzt werden sollen. Dabei wurde die Anzahl von standardmäßig 20 auf 100 erhöht. In Tabelle 5.4 sind die Ergebnisse aufgelistet.

Durch diese Erhöhung der Anzahl an Topics haben sich alle Werte verbessert. Für die Precision um bis zu 0,1, das entspricht einer Verbesserung von 10%.

5. Ergebnisse

Eine ebenfalls erhebliche Verbesserung ist bei den Coveragewerten erfolgt. Für den Korpus A von 2,6889 auf 2,4066 und bei Korpus B von 3,1402 auf 2,7636.

Die Erhöhung der Topicanzahl liefert somit auf jeden Fall bessere Ergebnisse.

Evaluationsmaße	Korpus A		Korpus B	
	Standard	Topics 100	Standard	Topics 100
Example-Based Precision	0.6602	0.7558	0.4888	0.6025
Example-Based Recall	0.7717	0.7895	0.7866	0.8048
Example-Based F_1 -Measure	0.7004	0.7625	0.5947	0.6740
Micro-averaged Precision	0.6361	0.7449	0.4777	0.5808
Micro-averaged Recall	0.7620	0.7796	0.7739	0.7930
Micro-averaged F_1 -Measure	0.6933	0.7617	0.5907	0.6703
Macro-averaged Precision	0.5086	0.6314	0.4876	0.5880
Macro-averaged Recall	0.5353	0.5501	0.5896	0.6034
Macro-averaged F_1 -Measure	0.4924	0.5505	0.4909	0.5539
Coverage	2.6889	2.4066	3.1402	2.7636
1-Error	0.1724	0.1602	0.3029	0.1811
R-Loss	0.0488	0.0401	0.0623	0.0484
Average Precision	0.8343	0.8574	0.7526	0.8263

Tabelle 5.4.: Ergebnisse der Kreuzvalidierung für SLDA

Eine Gesamtübersicht über die Ergebnisse für Naive Bayes mit überwachter Diskretisierung, SVM und SLDA mit der höheren Topicanzahl befindet sich in Tabelle 6.1.

Für die einzelnen Labels lassen sich auch jeweils Precision, Recall und F_1 -Measure über die Macro-averaged Werte Methode berechnen. In Tabelle 5.5 sind die Ergebnisse von beiden Korpus für Naive Bayes aufgelistet, in Tabelle 5.6 für SVM und in Tabelle 5.7 für SLDA.

Beim Naive Bayes sind bis auf das Label *livestock* die Werte im Korpus A relativ gut, für einige Labels liegen sie sogar oberhalb von 0,9. Für den Korpus B haben sich die Werte für das Label *livestock* sehr stark verbessert, die Precision ist von 0,0500 auf 0,3250 gestiegen, auch Recall und F_1 -Measure liegen oberhalb von 0,2.

Für die Ergebnisse bei der SVM sieht es ähnlich aus. Lediglich die Verbesserung des Labels *livestock* ist, vor allem bei der Precision nicht so erheblich, da es zu Beginn nicht so schlechte Werte hatte.

5. Ergebnisse

Labels	Korpus A			Korpus B		
	Precision	Recall	F_1 -M.	Precision	Recall	F_1 -M.
nat-gas	0.7561	0.8956	0.8115	0.7220	0.8969	0.7918
crude	0.9266	0.8915	0.9068	0.9342	0.8915	0.9118
grain	0.8411	0.9486	0.8895	0.8395	0.9544	0.8923
corn	0.4880	0.9647	0.6453	0.5149	0.9708	0.6699
wheat	0.6537	0.9726	0.7782	0.6443	0.9596	0.7690
acq	0.6257	0.8567	0.7141	0.6131	0.8298	0.6969
gold	0.9000	0.8250	0.8400	0.8500	0.8167	0.8300
oilseed	0.6538	0.7060	0.6690	0.6494	0.8055	0.7044
soybean	0.9000	0.7008	0.7617	0.7559	0.7865	0.7543
sugar	0.8000	0.5345	0.6200	0.7000	0.4833	0.5095
bop	0.5384	0.7946	0.6330	0.5410	0.7959	0.6320
trade	0.5156	0.7525	0.5989	0.4989	0.7954	0.6075
interest	0.8001	0.8612	0.8260	0.7942	0.8426	0.8154
money-fx	0.9235	0.9730	0.9473	0.9174	0.9596	0.9374
ship	0.9775	0.7814	0.8649	0.9800	0.7331	0.8331
earn	0.4190	0.8517	0.5527	0.4010	0.8267	0.5043
money-supply	0.2771	0.7000	0.3721	0.2371	0.5667	0.3108
dlr	0.7328	0.9259	0.8142	0.7341	0.9128	0.8116
gnp	0.3106	0.8815	0.4454	0.3244	0.8967	0.4651
veg-oil	0.7433	0.5842	0.6187	0.7933	0.5775	0.6307
coffee	0.7000	0.5250	0.5733	0.7667	0.7667	0.7433
livestock	0.0500	0.1000	0.0667	0.3250	0.2333	0.2200

Tabelle 5.5.: Evaluationsmaße für jedes Label von Naive Bayes mit überwachter Diskretisierung

Die Ergebnisse für den SLDA sind im allgemeinen schlechter. Das Label *livestock* hat auch hier die schlechtesten Werte aber verbessert sich von Korpus A zu Korpus B. Im Gegensatz zu Naive Bayes und SVM hat das Label *sugar* hier ebenfalls einen schlechten Wert, es verschlechtert sich noch um einiges von Korpus A zu Korpus B. Beim Naive Bayes lag die Precision hier bei 0,8000/0,7000, der Recall bei 0,5345/0,4833 und das F_1 -Measure bei 0,6200/0,5095.

Bei der SVM ist ein ähnlicher Unterschied zwischen Precision, Recall und F_1 -Measure zu sehen, die Precision ist hier bei 0,6500/0,7000, der Recall bei 0,2726/0,3450 und das F_1 -Measure bei 0,3617/0,4414.

Der SLDA liefert hier die schlechtesten Ergebnisse, so ist die Precision 0,2500/0,2000, der Recall 0,1167/0,0733 und das F_1 -Measure 0,1500/0,1019. Die Label *livestock* und *sugar* haben für den Korpus B die gleiche Precision, der Recall und das

5. Ergebnisse

Labels	Korpus A			Korpus B		
	Precision	Recall	F_1 -M.	Precision	Recall	F_1 -M.
nat-gas	0.9565	0.8730	0.9101	0.9314	0.8614	0.8901
crude	0.9596	0.9014	0.9283	0.9782	0.8818	0.9244
grain	0.9704	0.9553	0.9623	0.9575	0.9554	0.9556
corn	0.9388	0.9105	0.9208	0.9320	0.9253	0.9270
wheat	0.9334	0.9621	0.9469	0.9184	0.9442	0.9303
acq	0.9157	0.6391	0.7178	0.8740	0.5966	0.6950
gold	0.8000	0.7250	0.7400	0.7000	0.5667	0.6133
oilseed	0.8457	0.5516	0.6626	0.8584	0.5610	0.6645
soybean	0.9524	0.5967	0.7044	0.9225	0.5688	0.6860
sugar	0.6500	0.2726	0.3617	0.7000	0.3450	0.4414
bop	0.8869	0.7071	0.7791	0.9146	0.8201	0.8585
trade	0.8100	0.7130	0.7527	0.8191	0.7257	0.7630
interest	0.9173	0.8681	0.8885	0.9145	0.8654	0.8874
money-fx	0.9523	0.9684	0.9598	0.9480	0.9549	0.9509
ship	0.9186	0.7637	0.8267	0.9459	0.7856	0.8559
earn	0.7500	0.3317	0.4538	0.6500	0.3667	0.4376
money-supply	0.7667	0.6000	0.6433	0.5167	0.3083	0.3600
dlr	0.8706	0.8701	0.8665	0.8787	0.8630	0.8660
gnp	0.9306	0.6632	0.7639	0.9583	0.6895	0.7676
veg-oil	0.9000	0.3950	0.5294	0.8167	0.3792	0.4876
coffee	0.6000	0.3833	0.4424	0.6000	0.4583	0.4900
livestock	0.3000	0.1643	0.1917	0.4000	0.2583	0.2900

Tabelle 5.6.: Evaluationsmaße für jedes Label von SVM

F_1 -Measure sind allerdings für *sugar* wesentlich schlechter.

Durch die Zusammensetzung der Korpus sind alle Labels in ausreichender Häufigkeit im Korpus enthalten, somit sind diese gravierenden Unterschiede auf einer wesentlich schlechteren Abtrennung voneinander zu erklären.

Abschließend wird das Laufzeitverhalten der verschiedenen Algorithmen näher betrachtet (vgl. Tabelle 5.8). Die geringste Laufzeit hat jeweils die SVM mit 17 Minuten für Korpus A und 19 Minuten für Korpus B, der durchschnittliche Trainingsschritt hat für Korpus A 1,7 Minuten und für Korpus B 1,9 Minuten gedauert.

Beim Naive Bayes hat es jeweils mit den Standardoptionen am Kürzesten gedauert und mit dem Kerndichteabschätzer am längsten. Für den Naive Bayes mit

5. Ergebnisse

Labels	Korpus A			Korpus B		
	Precision	Recall	F_1 -M.	Precision	Recall	F_1 -M.
nat-gas	0.8393	0.8542	0.8326	0.8570	0.8283	0.8288
crude	0.9311	0.8280	0.8726	0.8852	0.8614	0.8706
grain	0.7693	0.9906	0.8637	0.7778	0.9875	0.8694
corn	0.7141	0.7332	0.7183	0.6264	0.7491	0.6762
wheat	0.5599	0.9453	0.7004	0.5834	0.8748	0.6989
acq	0.5335	0.4009	0.4406	0.5448	0.3827	0.4303
gold	0.4000	0.4000	0.4000	0.3000	0.3000	0.3000
oilseed	0.6000	0.1050	0.1759	0.3881	0.4451	0.3942
soybean	0.8667	0.3146	0.4446	0.0819	0.9457	0.1499
sugar	0.2500	0.1167	0.1500	0.2000	0.0733	0.1019
bop	0.7715	0.7207	0.7353	0.8060	0.7584	0.7710
trade	0.8704	0.5442	0.6635	0.9207	0.4934	0.6363
interest	0.9075	0.8451	0.8692	0.8751	0.8363	0.8509
money-fx	0.8753	0.9509	0.9104	0.8817	0.9612	0.9183
ship	0.8112	0.6883	0.7280	0.9187	0.7643	0.8277
earn	0.5800	0.3467	0.4105	0.5500	0.3400	0.3738
money-supply	0.4000	0.2583	0.2733	0.4000	0.1417	0.2067
dlr	0.5724	0.9738	0.7174	0.6352	0.9438	0.7551
gnp	0.8083	0.5333	0.6167	0.5163	0.6937	0.5611
veg-oil	0.5300	0.4125	0.4240	0.6883	0.3950	0.4649
coffee	0.2000	0.1250	0.1400	0.3000	0.3000	0.3000
livestock	0.1000	0.0143	0.0250	0.2000	0.2000	0.2000

Tabelle 5.7.: Evaluationsmaße für jedes Label von SLDA mit 100 Topics

überwachter Diskretisierung hat die Kreuzvalidierung für Korpus A 166 Minuten und für Korpus B 185 Minuten gedauert. Im Durchschnitt hat somit ein Trainingsschritt für Korpus A 16,6 Minuten und für Korpus B 18,5 Minuten gedauert.

Beim SLDA hat es mit Abstand am Längsten gedauert. Bei den Standardeinstellungen für Korpus A 1027 Minuten, das sind etwas mehr als 17 Stunden und für Korpus B 1164 Minuten, das sind 19,4 Stunden. Mit der erhöhten Topicanzahl hat es für Korpus A 2,9 Tage und für Korpus B 3 Tage gedauert. Der durchschnittliche Trainingsschritt hat hier 6,9 Stunden bzw. 7,1 Stunden gedauert.

5. Ergebnisse

	Laufzeit	
	Korpus A	Korpus B
Naive Bayes	139	156
Naive Bayes mit überwachter Diskretisierung	166	185
Naive Bayes mit Kerndichteabschätzer	175	187
SVM	17	19
SLDA	1027	1164
SLDA mit 100 Topics	4140	4263

Tabelle 5.8.: Laufzeiten der verschiedenen Kreuzvalidierungen, alle Angaben in Minuten

6. Fazit

Wie bereits im vorherigen Kapitel beschrieben sind die Ergebnisse für die bipartitionsbasierten Evaluationsmaße, von den Recallwerten abgesehen, jeweils bei der SVM am Besten. Für die Ranglisten basierten liefert der SLDA für das Coverage und das R-Loss die besten Ergebnisse ansonsten ebenfalls die SVM. Eine Übersicht über die Ergebnisse für die drei Klassifikationsverfahren und die beiden Korpus ist in Tabelle 6.1 aufgeführt.

Die aufgeführten Ergebnisse für Navie Bayes sind mit der überwachten Diskretisierung entstanden, die des SLDA mit der erhöhten Topicanzahl von 100.

	Korpus A			Korpus B		
	NB	SVM	SLDA	NB	SVM	SLDA
EB Precision	0.7516	0.8947	0.7558	0.7369	0.8940	0.6025
EB Recall	0.8823	0.8460	0.7895	0.8833	0.8412	0.8048
EB F_1 -Measure	0.7907	0.8592	0.7625	0.7826	0.8547	0.6740
Mi Precision	0.7087	0.9297	0.7449	0.6965	0.9243	0.5808
Mi Recall	0.8794	0.8381	0.7796	0.8799	0.8279	0.7930
Mi F_1 -Measure	0.7846	0.8813	0.7617	0.7773	0.8732	0.6703
Ma Precision	0.6606	0.8421	0.6314	0.6608	0.6673	0.5880
Ma Recall	0.7740	0.6734	0.5501	0.7864	0.7156	0.6034
Ma F_1 -Measure	0.6795	0.7251	0.5505	0.6837	0.9917	0.5539
Coverage	2.8770	3.4801	2.4066	2.9247	3.7009	2.7636
1-Error	0.1518	0.0885	0.1602	0.1569	0.0880	0.1811
R-Loss	0.0503	0.0638	0.0401	0.0487	0.0654	0.0484
Average Precision	0.8717	0.8856	0.8574	0.8713	0.8840	0.8263
Laufzeit (Minuten)	166	17	4140	185	19	4263

Tabelle 6.1.: Zusammenfassung der Ergebnisse der drei Klassifikationsverfahren für beide Korpus

Example-Based (EB), Micro-averaged (Mi) und Macro-averaged (Ma), Naive Bayes (NB)

Naive Bayes und SLDA liefern nahezu dieselben Ergebnisse. Dabei ist Naive Bayes allerdings wesentlich schneller als SLDA. Naive Bayes liefert, wie auch SLDA, bes-

6. Fazit

sere Ergebnisse für Coverage und R-Loss im Vergleich zur SVM. Für die Average Precision sind die Werte fast identisch mit denen der SVM. Allerdings sind die Precision-, Recall- und F_1 -Measurewerte für Naive Bayes nicht so gut wie die der SVM.

Die Laufzeit für die SVM ist jeweils am Geringsten, vor allem im Vergleich zum SLDA.

Die SVM ist für die Multi-Label Klassifikation somit die beste Wahl.

Die wesentlich besseren Ergebnisse des SLDA für Coverage und R-Loss sind durch den verwendeten Multi-Label Learner zu erklären. Wie im Kapitel 4 beschrieben wird im Trainingsschritt die maximale Anzahl der Labels im Korpus für die spätere Vorhersage benutzt. Somit können nur die beobachteten Menge der Labels pro Dokument auch wieder vorgesagt werden.

Die Entwicklung eines Multi-Label Learner für Topic Modelle der in der Lage ist, im Gegensatz zu dem oben beschriebenen, auch unbekannte Labelmengen vorherzusagen, muss noch einmal in einer anderen Arbeit erfolgen.

Auch der Einfluss der verschiedenen Preprocessing Schritte, welche im Abschnitt 2.3 erläutert sind, sollten noch einmal genauer untersucht werden.

7. Kurzzusammenfassung

Einem Text kann in der Regel mehr als ein Label zugeordnet werden. Nahezu alle Klassifikationsverfahren sind allerdings nur in der Lage ein Label pro Dokument zu verarbeiten.

In dieser Arbeit geht es um eine Evaluation zwischen Naive Bayes, Support Vector Machine (SVM), den binären Klassifikationsverfahren und Supervised Latent Dirichlet Allocation (SLDA), einem multiclass Klassifikationsverfahren.

Um eine Vergleichbarkeit zu erreichen wurde der C++-SLDA in Java implementiert werden.

Damit binäre Klassifikationsverfahren in der Lage sind Multi-Label Klassifikationen durchzuführen, benötigt es eine Reihe von Transformationen.

Für die benutzten binären Klassifikationsverfahren Naive Bayes und SVM wurde die Transformation *RAkEL* verwendet. Für den SLDA wurde ein eigener Topic Modell Multi-Label Learner entwickelt und verwendet.

Zur Klassifikation wird der Reuters-21578 Korpus verwendet. Da nicht alle enthaltenen Texte Labels haben und nicht alle vorkommenden Labels in ausreichender Häufigkeit vorliegen, wurde eine Auswahl der Texte getroffen. Am Ende werden zwei verschiedene Korpus erzeugt, die für die Klassifikation benutzt wurden.

Die Ergebnisse der Klassifikation zeigen, dass die SVM die besten Ergebnisse lieferte und Naive Bayes und SLDA in etwa gleich gut sind. Der Nachteil des SLDA liegt vor allem in dessen langer Laufzeit.

8. Literaturverzeichnis

- [1] Ricardo A. Baeza-Yates und Berthier Ribeiro-Neto. *Modern Information Retrieval*. Boston, MA, USA: Addison-Wesley Longman Publishing Co., Inc., 1999. ISBN: 020139829X.
- [2] Christopher M. Bishop. *Pattern Recognition and Machine Learning (Information Science and Statistics)*. Secaucus, NJ, USA: Springer-Verlag New York, Inc., 2006. ISBN: 0387310738.
- [3] D.M. Blei, A.Y. Ng und M.I. Jordan. „Latent dirichlet allocation“. In: *the Journal of machine Learning research* 3 (2003), S. 993–1022.
- [4] Kai-Uwe Carstensen u. a. *Computerlinguistik und Sprachtechnologie: Eine Einführung*. Hrsg. von Kai-Uwe Carstensen u. a. ISBN 3827420237. Springer, 2009.
- [5] DataMin. *Evaluation methods in text categorization*. Sep. 2013. URL: http://datamin.ubbcluj.ro/wiki/index.php?title=Evaluation_methods_in_text_categorization&oldid=2019.
- [6] George H. John und Pat Langley. „Estimating continuous distributions in Bayesian classifiers“. In: *Proceedings of the Eleventh conference on Uncertainty in artificial intelligence*. UAI'95. Montré#233;al, Qu#233;, Canada: Morgan Kaufmann Publishers Inc., 1995, S. 338–345. ISBN: 1-55860-385-9. URL: <http://dl.acm.org/citation.cfm?id=2074158.2074196>.
- [7] John C. Platt. *Sequential Minimal Optimization: A Fast Algorithm for Training Support Vector Machines*. Techn. Ber. ADVANCES IN KERNEL METHODS - SUPPORT VECTOR LEARNING, 1998.
- [8] Daniel Ramage u. a. „Labeled LDA: a supervised topic model for credit attribution in multi-labeled corpora“. In: *Proceedings of the 2009 Conference on Empirical Methods in Natural Language Processing: Volume 1 - Volume 1*. EMNLP '09. Singapore: Association for Computational Linguistics, 2009, S. 248–256. ISBN: 978-1-932432-59-6. URL: <http://dl.acm.org/citation.cfm?id=1699510.1699543>.
- [9] TimothyN. Rubin u. a. „Statistical topic models for multi-label document classification“. English. In: *Machine Learning* 88 (1-2 2012), S. 157–208. ISSN: 0885-6125. DOI: 10.1007/s10994-011-5272-5. URL: <http://dx.doi.org/10.1007/s10994-011-5272-5>.

8. Literaturverzeichnis

- [10] Michael Scharkow. „Automatische Inhaltsanalyse und maschinelles Lernen“. Diss. 2012.
- [11] Bernhard Scholkopf und Alexander J. Smola. *Learning with Kernels: Support Vector Machines, Regularization, Optimization, and Beyond*. Cambridge, MA, USA: MIT Press, 2001. ISBN: 0262194759.
- [12] Grigorios Tsoumakas, Ioannis Katakis und Ioannis Vlahavas. „Mining multi-label data“. In: *In Data Mining and Knowledge Discovery Handbook*. 2010, S. 667–685.
- [13] Grigorios Tsoumakas, Ioannis Katakis und Ioannis Vlahavas. „Random k-Labelsets for Multi-Label Classification“. In: *IEEE Transactions on Knowledge and Data Engineering* 99.1 (2010). Hrsg. von IEEE. ISSN: 1041-4347. DOI: 10.1109/TKDE.2010.164. URL: <http://www.computer.org/portal/web/csdl/doi/10.1109/TKDE.2010.164>.
- [14] Chong Wang, David M. Blei und Li Fei-Fei. „Simultaneous Image Classification and Annotation“. In: 2009. URL: http://cs.stanford.edu/groups/vision/documents/WangBleiFei-Fei_CVPR2009.pdf.
- [15] Shuang hong Yang, Hongyuan Zha und Bao gang Hu. *Dirichlet-Bernoulli Alignment: A Generative Model for Multi-Class Multi-Label Multi-Instance Corpora*.
- [16] Harry Zhang. „The Optimality of Naive Bayes“. In: *Proceedings of the Seventeenth International Florida Artificial Intelligence Research Society Conference (FLAIRS 2004)*. May 17-19, 2004. (Miami Beach, Florida, USA). Hrsg. von Valerie Barr und Zdravko Markov. AAAI Press, 2004.

A. Topic Modell Multi-Label Learner Ergebnisse

A.1. Schwellwert 0,08

ElapsedTime: 67164.344
Hamming Loss: 0.1114±0.0052
Subset Accuracy: 0.0227±0.0152
Example-Based Precision: 0.4766±0.0173
Example-Based Recall: 0.7786±0.0217
Example-Based F Measure: 0.5833±0.0166
Example-Based Accuracy: 0.4438±0.0165
Example-Based Specificity: 0.9024±0.0043
Micro-averaged Precision: 0.4661±0.0160
Micro-averaged Recall: 0.7668±0.0222
Micro-averaged F-Measure: 0.5797±0.0171
Micro-averaged Specificity: 0.9022±0.0043
Macro-averaged Precision: 0.4731±0.0373
label_nat-gas: 0.7444±0.0981 label_crude: 0.8476±0.0784 label_grain:
0.7770±0.0803 label_corn: 0.4934±0.0582 label_wheat: 0.4781±0.0538
label_acq: 0.5696±0.1293 label_gold: 0.4000±0.2240 label_oilseed:
0.1805±0.0271 label_soybean: 0.0687±0.0052 label_sugar: 0.0000±0
.0000 label_bop: 0.7292±0.1113 label_trade: 0.7519±0.1043
label_interest: 0.8416±0.0919 label_money-fx: 0.8657±0.0848
label_ship: 0.8004±0.1162 label_earn: 0.3714±0.1783 label_money-
supply: 0.1000±0.0890 label_dlr: 0.4426±0.0572 label_gnp: 0.3719±0
.0949 label_veg-oil: 0.1247±0.0163 label_coffee: 0.2000±0.1560
label_livestock: 0.2500±0.1563
Macro-averaged Recall: 0.5756±0.0480
label_nat-gas: 0.7764±0.0449 label_crude: 0.8270±0.0844 label_grain:
0.9790±0.0968 label_corn: 0.5816±0.0709 label_wheat: 0.7698±0.0805
label_acq: 0.3863±0.0795 label_gold: 0.3500±0.1903 label_oilseed:
0.4568±0.0833 label_soybean: 0.9700±0.1040 label_sugar: 0.0000±0
.0000 label_bop: 0.6783±0.0975 label_trade: 0.6036±0.0873
label_interest: 0.8124±0.0993 label_money-fx: 0.9408±0.0985
label_ship: 0.7201±0.0838 label_earn: 0.3400±0.2044 label_money-
supply: 0.0333±0.0099 label_dlr: 0.9557±0.1039 label_gnp: 0.6863±0
.1036 label_veg-oil: 0.3700±0.1043 label_coffee: 0.2000±0.1560
label_livestock: 0.2250±0.1506
Macro-averaged F-Measure: 0.4794±0.0381

A. Topic Modell Multi-Label Learner Ergebnisse

label_nat-gas: 0.7419±0.0590 label_crude: 0.8359±0.0803 label_grain:
0.8652±0.0870 label_corn: 0.5271±0.0607 label_wheat: 0.5853±0.0618
label_acq: 0.4266±0.0808 label_gold: 0.3667±0.1966 label_oilseed:
0.2424±0.0385 label_soybean: 0.1278±0.0101 label_sugar: 0.0000±0
.0000 label_bop: 0.6910±0.0938 label_trade: 0.6587±0.0881
label_interest: 0.8255±0.0947 label_money-fx: 0.9000±0.0898
label_ship: 0.7483±0.0914 label_earn: 0.3119±0.1476 label_money-
supply: 0.0500±0.0223 label_dlr: 0.5958±0.0731 label_gnp: 0.4418±0
.0828 label_veg-oil: 0.1716±0.0266 label_coffee: 0.2000±0.1560
label_livestock: 0.2333±0.1512
Macro-averaged Specificity: 0.9000±0.0044
label_nat-gas: 0.9821±0.0994 label_crude: 0.9770±0.0969 label_grain:
0.8440±0.0820 label_corn: 0.8853±0.0869 label_wheat: 0.7890±0.0838
label_acq: 0.9845±0.0978 label_gold: 1.0000±0.1000 label_oilseed:
0.7819±0.0926 label_soybean: 0.1523±0.0141 label_sugar: 0.9894±0
.1004 label_bop: 0.9837±0.0979 label_trade: 0.9701±0.0991
label_interest: 0.9722±0.0976 label_money-fx: 0.9284±0.0930
label_ship: 0.9789±0.1002 label_earn: 0.9918±0.0985 label_money-
supply: 0.9926±0.1001 label_dlr: 0.7674±0.0838 label_gnp: 0.9399±0
.0970 label_veg-oil: 0.8965±0.0860 label_coffee: 1.0000±0.1000
label_livestock: 0.9925±0.1002
Average Precision: 0.7679±0.0389
Coverage: 3.0319±0.2746
OneError: 0.2808±0.0900
IsError: 0.6099±0.0673
ErrorSetSize: 2.6178±0.4057
Ranking Loss: 0.0588±0.0093
Mean Average Precision: 0.5579±0.0265
label_nat-gas: 0.7321±0.0661 label_crude: 0.8333±0.0791 label_grain:
0.9082±0.0987 label_corn: 0.4694±0.0676 label_wheat: 0.6361±0.0646
label_acq: 0.5740±0.0891 label_gold: NaN±NaN label_oilseed: 0.2997
±0.0279 label_soybean: 0.2734±0.0381 label_sugar: 0.1488±0.0125
label_bop: 0.7699±0.1069 label_trade: 0.6485±0.0810 label_interest:
0.8344±0.0959 label_money-fx: 0.9650±0.0954 label_ship: 0.7179±0
.0881 label_earn: 0.2990±0.0489 label_money-supply: 0.2447±0.0444
label_dlr: 0.8022±0.0784 label_gnp: 0.6697±0.0784 label_veg-oil:
0.3136±0.0978 label_coffee: NaN±NaN label_livestock: NaN±NaN
Geometric Mean Average Precision: NaN±NaN
label_nat-gas: 0.7321±0.0661 label_crude: 0.8333±0.0791 label_grain:
0.9082±0.0987 label_corn: 0.4694±0.0676 label_wheat: 0.6361±0.0646
label_acq: 0.5740±0.0891 label_gold: NaN±NaN label_oilseed: 0.2997
±0.0279 label_soybean: 0.2734±0.0381 label_sugar: 0.1488±0.0125
label_bop: 0.7699±0.1069 label_trade: 0.6485±0.0810 label_interest:
0.8344±0.0959 label_money-fx: 0.9650±0.0954 label_ship: 0.7179±0
.0881 label_earn: 0.2990±0.0489 label_money-supply: 0.2447±0.0444
label_dlr: 0.8022±0.0784 label_gnp: 0.6697±0.0784 label_veg-oil:
0.3136±0.0978 label_coffee: NaN±NaN label_livestock: NaN±NaN
Mean Average Interpolated Precision: 0.5720±0.0257

A. Topic Modell Multi-Label Learner Ergebnisse

label_nat-gas: 0.7586±0.0625 label_crude: 0.8365±0.0775 label_grain:
0.9055±0.0974 label_corn: 0.5086±0.0703 label_wheat: 0.6765±0.0656
label_acq: 0.6041±0.0870 label_gold: NaN±NaN label_oilseed: 0.3329
±0.0332 label_soybean: 0.2949±0.0435 label_sugar: 0.1617±0.0149
label_bop: 0.7705±0.1076 label_trade: 0.6665±0.0828 label_interest:
0.8305±0.0939 label_money-fx: 0.9557±0.0944 label_ship: 0.7155±0
.0837 label_earn: 0.3284±0.0578 label_money-supply: 0.2620±0.0507
label_dlr: 0.8200±0.0800 label_gnp: 0.6748±0.0801 label_veg-oil:
0.3215±0.0947 label_coffee: NaN±NaN label_livestock: NaN±NaN
Geometric Mean Average Interpolated Precision: NaN±NaN
label_nat-gas: 0.7586±0.0625 label_crude: 0.8365±0.0775 label_grain:
0.9055±0.0974 label_corn: 0.5086±0.0703 label_wheat: 0.6765±0.0656
label_acq: 0.6041±0.0870 label_gold: NaN±NaN label_oilseed: 0.3329
±0.0332 label_soybean: 0.2949±0.0435 label_sugar: 0.1617±0.0149
label_bop: 0.7705±0.1076 label_trade: 0.6665±0.0828 label_interest:
0.8305±0.0939 label_money-fx: 0.9557±0.0944 label_ship: 0.7155±0
.0837 label_earn: 0.3284±0.0578 label_money-supply: 0.2620±0.0507
label_dlr: 0.8200±0.0800 label_gnp: 0.6748±0.0801 label_veg-oil:
0.3215±0.0947 label_coffee: NaN±NaN label_livestock: NaN±NaN
Micro-averaged AUC: 0.9381±0.0086
Macro-averaged AUC: NaN±NaN
label_nat-gas: 0.9738±0.0949 label_crude: 0.9636±0.0958 label_grain:
0.9565±0.0981 label_corn: 0.8641±0.0912 label_wheat: 0.9004±0.0872
label_acq: 0.9367±0.0964 label_gold: NaN±NaN label_oilseed: 0.8153
±0.0754 label_soybean: 0.7830±0.0811 label_sugar: 0.7035±0.1073
label_bop: 0.9704±0.0991 label_trade: 0.9260±0.0960 label_interest:
0.9592±0.0975 label_money-fx: 0.9831±0.0980 label_ship: 0.9231±0
.0888 label_earn: 0.9446±0.0979 label_money-supply: 0.9092±0.0918
label_dlr: 0.9626±0.0955 label_gnp: 0.9592±0.0977 label_veg-oil:
0.8131±0.1036 label_coffee: NaN±NaN label_livestock: NaN±NaN

A.2. Schwellwert 0,09

ElapsedTime: 69704.648
Hamming Loss: 0.0693±0.0075
Subset Accuracy: 0.2335±0.0306
Example-Based Precision: 0.6381±0.0321
Example-Based Recall: 0.7681±0.0386
Example-Based F Measure: 0.6874±0.0335
Example-Based Accuracy: 0.5895±0.0321
Example-Based Specificity: 0.9491±0.0046
Micro-averaged Precision: 0.6153±0.0326
Micro-averaged Recall: 0.7598±0.0367
Micro-averaged F-Measure: 0.6799±0.0341
Micro-averaged Specificity: 0.9490±0.0046
Macro-averaged Precision: 0.4743±0.0666
label_nat-gas: 0.7525±0.1285 label_crude: 0.8043±0.0920 label_grain:
0.7750±0.0745 label_corn: 0.4902±0.0497 label_wheat: 0.4509±0.0413

A. Topic Modell Multi-Label Learner Ergebnisse

label_acq: 0.3921±0.0495 label_gold: 0.5000±0.3250 label_oilseed:
0.0474±0.0042 label_soybean: 0.0000±0.0000 label_sugar: 0.1833±0
.0991 label_bop: 0.7583±0.1403 label_trade: 0.7696±0.1016
label_interest: 0.8842±0.0991 label_money-fx: 0.8892±0.0829
label_ship: 0.6347±0.1084 label_earn: 0.2976±0.1407 label_money-
supply: 0.2500±0.2063 label_dlr: 0.4665±0.0326 label_gnp: 0.7550±0
.1411 label_veg-oil: 0.1328±0.0202 label_coffee: 0.1000±0.1090
label_livestock: 0.1000±0.1090
Macro-averaged Recall: 0.5317±0.0565
label_nat-gas: 0.7656±0.1114 label_crude: 0.8632±0.0997 label_grain:
0.9878±0.1003 label_corn: 0.5394±0.0948 label_wheat: 0.9211±0.0926
label_acq: 0.4784±0.0630 label_gold: 0.5000±0.3250 label_oilseed:
0.0668±0.0067 label_soybean: 0.0000±0.0000 label_sugar: 0.1167±0
.0323 label_bop: 0.6799±0.0942 label_trade: 0.6151±0.0654
label_interest: 0.8720±0.0892 label_money-fx: 0.9489±0.0947
label_ship: 0.6648±0.1015 label_earn: 0.2000±0.0491 label_money-
supply: 0.2000±0.1510 label_dlr: 0.9734±0.1011 label_gnp: 0.5167±0
.0495 label_veg-oil: 0.5883±0.0737 label_coffee: 0.1000±0.1090
label_livestock: 0.1000±0.1090
Macro-averaged F-Measure: 0.4744±0.0581
label_nat-gas: 0.7361±0.1090 label_crude: 0.8310±0.0944 label_grain:
0.8665±0.0841 label_corn: 0.4996±0.0658 label_wheat: 0.6009±0.0555
label_acq: 0.3901±0.0316 label_gold: 0.5000±0.3250 label_oilseed:
0.0531±0.0046 label_soybean: 0.0000±0.0000 label_sugar: 0.1333±0
.0416 label_bop: 0.7057±0.1086 label_trade: 0.6699±0.0720
label_interest: 0.8731±0.0901 label_money-fx: 0.9156±0.0863
label_ship: 0.6191±0.0912 label_earn: 0.2133±0.0610 label_money-
supply: 0.2167±0.1689 label_dlr: 0.6238±0.0468 label_gnp: 0.5824±0
.0651 label_veg-oil: 0.2070±0.0321 label_coffee: 0.1000±0.1090
label_livestock: 0.1000±0.1090
Macro-averaged Specificity: 0.9451±0.0052
label_nat-gas: 0.9806±0.1003 label_crude: 0.9664±0.0967 label_grain:
0.8488±0.0844 label_corn: 0.9093±0.0877 label_wheat: 0.7265±0.0704
label_acq: 0.9574±0.0989 label_gold: 1.0000±0.1000 label_oilseed:
0.9596±0.0958 label_soybean: 0.9976±0.1000 label_sugar: 0.9875±0
.1003 label_bop: 0.9871±0.0984 label_trade: 0.9740±0.0965
label_interest: 0.9763±0.0993 label_money-fx: 0.9435±0.0922
label_ship: 0.9522±0.0968 label_earn: 0.9914±0.0994 label_money-
supply: 0.9969±0.1000 label_dlr: 0.7907±0.0738 label_gnp: 0.9929±0
.0992 label_veg-oil: 0.8539±0.0954 label_coffee: 1.0000±0.1000
label_livestock: 1.0000±0.1000
Average Precision: 0.8298±0.0277
Coverage: 2.6514±0.3357
OneError: 0.1815±0.0459
IsError: 0.4439±0.0347
ErrorSetSize: 2.0670±0.4597
Ranking Loss: 0.0476±0.0111
Mean Average Precision: 0.5602±0.0317

A. Topic Modell Multi-Label Learner Ergebnisse

label_nat-gas: 0.6946±0.0970 label_crude: 0.8374±0.0981 label_grain:
0.9036±0.0895 label_corn: 0.4406±0.0612 label_wheat: 0.6587±0.0653
label_acq: 0.5281±0.0670 label_gold: NaN±NaN label_oilseed: 0.2273
±0.0335 label_soybean: 0.2057±0.0528 label_sugar: 0.0961±0.0104
label_bop: 0.8095±0.1104 label_trade: 0.6580±0.0908 label_interest:
0.8832±0.0982 label_money-fx: 0.9676±0.0937 label_ship: 0.7210±0
.1020 label_earn: 0.2357±0.0531 label_money-supply: NaN±NaN
label_dlr: 0.8021±0.0797 label_gnp: 0.6904±0.1182 label_veg-oil:
0.3196±0.0592 label_coffee: NaN±NaN label_livestock: NaN±NaN
Geometric Mean Average Precision: NaN±NaN
label_nat-gas: 0.6946±0.0970 label_crude: 0.8374±0.0981 label_grain:
0.9036±0.0895 label_corn: 0.4406±0.0612 label_wheat: 0.6587±0.0653
label_acq: 0.5281±0.0670 label_gold: NaN±NaN label_oilseed: 0.2273
±0.0335 label_soybean: 0.2057±0.0528 label_sugar: 0.0961±0.0104
label_bop: 0.8095±0.1104 label_trade: 0.6580±0.0908 label_interest:
0.8832±0.0982 label_money-fx: 0.9676±0.0937 label_ship: 0.7210±0
.1020 label_earn: 0.2357±0.0531 label_money-supply: NaN±NaN
label_dlr: 0.8021±0.0797 label_gnp: 0.6904±0.1182 label_veg-oil:
0.3196±0.0592 label_coffee: NaN±NaN label_livestock: NaN±NaN
Mean Average Interpolated Precision: 0.5737±0.0344
label_nat-gas: 0.7219±0.0943 label_crude: 0.8365±0.0964 label_grain:
0.9046±0.0877 label_corn: 0.4758±0.0644 label_wheat: 0.6942±0.0666
label_acq: 0.5621±0.0675 label_gold: NaN±NaN label_oilseed: 0.2596
±0.0413 label_soybean: 0.2218±0.0561 label_sugar: 0.1040±0.0122
label_bop: 0.8145±0.1052 label_trade: 0.6701±0.0907 label_interest:
0.8858±0.0951 label_money-fx: 0.9598±0.0926 label_ship: 0.7041±0
.0945 label_earn: 0.2646±0.0571 label_money-supply: NaN±NaN
label_dlr: 0.8137±0.0782 label_gnp: 0.6946±0.1149 label_veg-oil:
0.3379±0.0605 label_coffee: NaN±NaN label_livestock: NaN±NaN
Geometric Mean Average Interpolated Precision: NaN±NaN
label_nat-gas: 0.7219±0.0943 label_crude: 0.8365±0.0964 label_grain:
0.9046±0.0877 label_corn: 0.4758±0.0644 label_wheat: 0.6942±0.0666
label_acq: 0.5621±0.0675 label_gold: NaN±NaN label_oilseed: 0.2596
±0.0413 label_soybean: 0.2218±0.0561 label_sugar: 0.1040±0.0122
label_bop: 0.8145±0.1052 label_trade: 0.6701±0.0907 label_interest:
0.8858±0.0951 label_money-fx: 0.9598±0.0926 label_ship: 0.7041±0
.0945 label_earn: 0.2646±0.0571 label_money-supply: NaN±NaN
label_dlr: 0.8137±0.0782 label_gnp: 0.6946±0.1149 label_veg-oil:
0.3379±0.0605 label_coffee: NaN±NaN label_livestock: NaN±NaN
Micro-averaged AUC: 0.9501±0.0098
Macro-averaged AUC: NaN±NaN
label_nat-gas: 0.9661±0.0965 label_crude: 0.9565±0.0992 label_grain:
0.9558±0.0939 label_corn: 0.8653±0.0923 label_wheat: 0.9087±0.0885
label_acq: 0.9307±0.0856 label_gold: NaN±NaN label_oilseed: 0.8051
±0.0877 label_soybean: 0.7911±0.0983 label_sugar: 0.7341±0.0830
label_bop: 0.9783±0.0977 label_trade: 0.9210±0.0932 label_interest:
0.9737±0.0977 label_money-fx: 0.9845±0.0973 label_ship: 0.9112±0
.0981 label_earn: 0.9306±0.0980 label_money-supply: NaN±NaN
label_dlr: 0.9613±0.0957 label_gnp: 0.9694±0.0945 label_veg-oil:

A. Topic Modell Multi-Label Learner Ergebnisse

0.8110±0.0925 label_coffee: NaN±NaN label_livestock: NaN±NaN

A.3. Schwellwert 0,10

ElapsedTime: 82594.512
Hamming Loss: 0.0679±0.0076
Subset Accuracy: 0.2442±0.0395
Example-Based Precision: 0.6450±0.0355
Example-Based Recall: 0.7713±0.0367
Example-Based F Measure: 0.6926±0.0332
Example-Based Accuracy: 0.5952±0.0338
Example-Based Specificity: 0.9503±0.0055
Micro-averaged Precision: 0.6224±0.0330
Micro-averaged Recall: 0.7628±0.0349
Micro-averaged F-Measure: 0.6853±0.0320
Micro-averaged Specificity: 0.9503±0.0055
Macro-averaged Precision: 0.4954±0.0506
label_nat-gas: 0.7649±0.1281 label_crude: 0.8157±0.0845 label_grain:
0.7742±0.0807 label_corn: 0.4529±0.0444 label_wheat: 0.4911±0.0455
label_acq: 0.4348±0.0387 label_gold: 0.5000±0.3250 label_oilseed:
0.0200±0.0036 label_soybean: 0.1000±0.0890 label_sugar: 0.1000±0
.0890 label_bop: 0.7514±0.1338 label_trade: 0.7576±0.1036
label_interest: 0.8543±0.0966 label_money-fx: 0.8862±0.0837
label_ship: 0.6537±0.0912 label_earn: 0.4167±0.2951 label_money-
supply: 0.3200±0.1414 label_dlr: 0.4465±0.0278 label_gnp: 0.7467±0
.1945 label_veg-oil: 0.2112±0.0533 label_coffee: 0.3000±0.2610
label_livestock: 0.1000±0.1090
Macro-averaged Recall: 0.5457±0.0478
label_nat-gas: 0.6625±0.1281 label_crude: 0.8757±0.0978 label_grain:
0.9766±0.1011 label_corn: 0.5471±0.0728 label_wheat: 0.9002±0.0775
label_acq: 0.6915±0.0412 label_gold: 0.5000±0.3250 label_oilseed:
0.0100±0.0009 label_soybean: 0.0200±0.0036 label_sugar: 0.0143±0
.0018 label_bop: 0.7190±0.1077 label_trade: 0.5946±0.0715
label_interest: 0.8550±0.0842 label_money-fx: 0.9440±0.0979
label_ship: 0.7014±0.1078 label_earn: 0.2650±0.1465 label_money-
supply: 0.3083±0.1378 label_dlr: 0.9797±0.1010 label_gnp: 0.4740±0
.1176 label_veg-oil: 0.6917±0.0925 label_coffee: 0.1750±0.1326
label_livestock: 0.1000±0.1090
Macro-averaged F-Measure: 0.4868±0.0470
label_nat-gas: 0.6916±0.1204 label_crude: 0.8414±0.0879 label_grain:
0.8622±0.0889 label_corn: 0.4850±0.0515 label_wheat: 0.6305±0.0561
label_acq: 0.5243±0.0396 label_gold: 0.5000±0.3250 label_oilseed:
0.0133±0.0016 label_soybean: 0.0333±0.0099 label_sugar: 0.0250±0
.0056 label_bop: 0.7236±0.1130 label_trade: 0.6530±0.0778
label_interest: 0.8516±0.0876 label_money-fx: 0.9131±0.0895
label_ship: 0.6478±0.0885 label_earn: 0.3105±0.1831 label_money-
supply: 0.2817±0.1044 label_dlr: 0.6027±0.0399 label_gnp: 0.5236±0
.1037 label_veg-oil: 0.2881±0.0626 label_coffee: 0.2067±0.1548

A. Topic Modell Multi-Label Learner Ergebnisse

label_livestock: 0.1000±0.1090
Macro-averaged Specificity: 0.9463±0.0054
label_nat-gas: 0.9862±0.1002 label_crude: 0.9672±0.0948 label_grain:
0.8516±0.0881 label_corn: 0.8893±0.0843 label_wheat: 0.7694±0.0813
label_acq: 0.9494±0.0948 label_gold: 1.0000±0.1000 label_oilseed:
0.9845±0.0985 label_soybean: 0.9992±0.1000 label_sugar: 0.9938±0
.0993 label_bop: 0.9863±0.0993 label_trade: 0.9743±0.0974
label_interest: 0.9708±0.0992 label_money-fx: 0.9430±0.0927
label_ship: 0.9547±0.0948 label_earn: 0.9945±0.1001 label_money-
supply: 0.9899±0.1001 label_dlr: 0.7573±0.0636 label_gnp: 0.9936±0
.1001 label_veg-oil: 0.8642±0.1014 label_coffee: 1.0000±0.1000
label_livestock: 0.9992±0.1000
Average Precision: 0.8253±0.0305
Coverage: 2.6627±0.4302
OneError: 0.1846±0.0435
IsError: 0.4637±0.0445
ErrorSetSize: 2.0776±0.5630
Ranking Loss: 0.0484±0.0135
Mean Average Precision: 0.5434±0.0391
label_nat-gas: 0.7924±0.1084 label_crude: 0.8604±0.0975 label_grain:
0.8881±0.0900 label_corn: 0.4446±0.0495 label_wheat: 0.6348±0.0543
label_acq: 0.5195±0.0898 label_gold: NaN±NaN label_oilseed: 0.1885
±0.0275 label_soybean: 0.1874±0.0419 label_sugar: 0.1471±0.0393
label_bop: 0.7293±0.1262 label_trade: 0.6852±0.0978 label_interest:
0.8955±0.0978 label_money-fx: 0.9688±0.0954 label_ship: 0.7292±0
.1086 label_earn: 0.2252±0.0413 label_money-supply: NaN±NaN
label_dlr: 0.7744±0.0644 label_gnp: 0.6389±0.1138 label_veg-oil:
0.2676±0.0801 label_coffee: NaN±NaN label_livestock: NaN±NaN
Geometric Mean Average Precision: NaN±NaN
label_nat-gas: 0.7924±0.1084 label_crude: 0.8604±0.0975 label_grain:
0.8881±0.0900 label_corn: 0.4446±0.0495 label_wheat: 0.6348±0.0543
label_acq: 0.5195±0.0898 label_gold: NaN±NaN label_oilseed: 0.1885
±0.0275 label_soybean: 0.1874±0.0419 label_sugar: 0.1471±0.0393
label_bop: 0.7293±0.1262 label_trade: 0.6852±0.0978 label_interest:
0.8955±0.0978 label_money-fx: 0.9688±0.0954 label_ship: 0.7292±0
.1086 label_earn: 0.2252±0.0413 label_money-supply: NaN±NaN
label_dlr: 0.7744±0.0644 label_gnp: 0.6389±0.1138 label_veg-oil:
0.2676±0.0801 label_coffee: NaN±NaN label_livestock: NaN±NaN
Mean Average Interpolated Precision: 0.5553±0.0393
label_nat-gas: 0.8064±0.1053 label_crude: 0.8578±0.0951 label_grain:
0.8932±0.0891 label_corn: 0.4879±0.0545 label_wheat: 0.6713±0.0591
label_acq: 0.5540±0.0834 label_gold: NaN±NaN label_oilseed: 0.2090
±0.0302 label_soybean: 0.2074±0.0450 label_sugar: 0.1615±0.0458
label_bop: 0.7475±0.1124 label_trade: 0.6860±0.0944 label_interest:
0.8867±0.0962 label_money-fx: 0.9605±0.0947 label_ship: 0.7209±0
.0994 label_earn: 0.2522±0.0449 label_money-supply: NaN±NaN
label_dlr: 0.7875±0.0698 label_gnp: 0.6426±0.1105 label_veg-oil:
0.2880±0.0847 label_coffee: NaN±NaN label_livestock: NaN±NaN
Geometric Mean Average Interpolated Precision: NaN±NaN

A. Topic Modell Multi-Label Learner Ergebnisse

label_nat-gas: 0.8064±0.1053 label_crude: 0.8578±0.0951 label_grain:
0.8932±0.0891 label_corn: 0.4879±0.0545 label_wheat: 0.6713±0.0591
label_acq: 0.5540±0.0834 label_gold: NaN±NaN label_oilseed: 0.2090
±0.0302 label_soybean: 0.2074±0.0450 label_sugar: 0.1615±0.0458
label_bop: 0.7475±0.1124 label_trade: 0.6860±0.0944 label_interest:
0.8867±0.0962 label_money-fx: 0.9605±0.0947 label_ship: 0.7209±0
.0994 label_earn: 0.2522±0.0449 label_money-supply: NaN±NaN
label_dlr: 0.7875±0.0698 label_gnp: 0.6426±0.1105 label_veg-oil:
0.2880±0.0847 label_coffee: NaN±NaN label_livestock: NaN±NaN
Micro-averaged AUC: 0.9492±0.0121
Macro-averaged AUC: NaN±NaN
label_nat-gas: 0.9697±0.0967 label_crude: 0.9685±0.0983 label_grain:
0.9509±0.0950 label_corn: 0.8668±0.0912 label_wheat: 0.9081±0.0850
label_acq: 0.9315±0.0864 label_gold: NaN±NaN label_oilseed: 0.7661
±0.0757 label_soybean: 0.8083±0.0900 label_sugar: 0.8029±0.0791
label_bop: 0.9657±0.0980 label_trade: 0.9246±0.0966 label_interest:
0.9705±0.0989 label_money-fx: 0.9847±0.0981 label_ship: 0.9141±0
.0986 label_earn: 0.9344±0.0967 label_money-supply: NaN±NaN
label_dlr: 0.9506±0.0930 label_gnp: 0.9591±0.0961 label_veg-oil:
0.7662±0.0828 label_coffee: NaN±NaN label_livestock: NaN±NaN

A.4. Schwellwert 0,11

ElapsedTime: 62591.34
Hamming Loss: 0.0655±0.0072
Subset Accuracy: 0.2655±0.0393
Example-Based Precision: 0.6564±0.0322
Example-Based Recall: 0.7704±0.0404
Example-Based F Measure: 0.6985±0.0345
Example-Based Accuracy: 0.6033±0.0349
Example-Based Specificity: 0.9530±0.0045
Micro-averaged Precision: 0.6351±0.0316
Micro-averaged Recall: 0.7627±0.0373
Micro-averaged F-Measure: 0.6930±0.0331
Micro-averaged Specificity: 0.9530±0.0045
Macro-averaged Precision: 0.4878±0.0548
label_nat-gas: 0.7900±0.0707 label_crude: 0.8548±0.0870 label_grain:
0.7730±0.0792 label_corn: 0.5141±0.0531 label_wheat: 0.5137±0.0432
label_acq: 0.4646±0.0624 label_gold: 0.4000±0.3040 label_oilseed:
0.1833±0.0283 label_soybean: 0.0000±0.0000 label_sugar: 0.0700±0
.0236 label_bop: 0.7850±0.1196 label_trade: 0.7494±0.0957
label_interest: 0.8674±0.0882 label_money-fx: 0.8863±0.0919
label_ship: 0.7621±0.1020 label_earn: 0.2533±0.0445 label_money-
supply: 0.2500±0.1563 label_dlr: 0.4683±0.0350 label_gnp: 0.6989±0
.1405 label_veg-oil: 0.1473±0.0248 label_coffee: 0.1000±0.1090
label_livestock: 0.2000±0.1960
Macro-averaged Recall: 0.5364±0.0415

A. Topic Modell Multi-Label Learner Ergebnisse

label_nat-gas: 0.7824±0.0777 label_crude: 0.8204±0.0998 label_grain:
0.9759±0.0955 label_corn: 0.6040±0.0704 label_wheat: 0.9270±0.0880
label_acq: 0.5529±0.1088 label_gold: 0.4000±0.3040 label_oilseed:
0.0839±0.0054 label_soybean: 0.0000±0.0000 label_sugar: 0.0643±0
.0225 label_bop: 0.6724±0.0826 label_trade: 0.6756±0.0947
label_interest: 0.8416±0.0886 label_money-fx: 0.9454±0.0928
label_ship: 0.7058±0.1027 label_earn: 0.2733±0.0574 label_money-
supply: 0.2250±0.1481 label_dlr: 0.9493±0.1045 label_gnp: 0.5258±0
.0834 label_veg-oil: 0.5258±0.0621 label_coffee: 0.1000±0.1090
label_livestock: 0.1500±0.1302
Macro-averaged F-Measure: 0.4875±0.0462
label_nat-gas: 0.7719±0.0622 label_crude: 0.8279±0.0875 label_grain:
0.8601±0.0853 label_corn: 0.5428±0.0538 label_wheat: 0.6596±0.0574
label_acq: 0.4906±0.0780 label_gold: 0.4000±0.3040 label_oilseed:
0.1111±0.0098 label_soybean: 0.0000±0.0000 label_sugar: 0.0508±0
.0103 label_bop: 0.7048±0.0847 label_trade: 0.6924±0.0838
label_interest: 0.8506±0.0855 label_money-fx: 0.9135±0.0913
label_ship: 0.7220±0.0966 label_earn: 0.2528±0.0438 label_money-
supply: 0.2167±0.1245 label_dlr: 0.6182±0.0494 label_gnp: 0.5700±0
.0823 label_veg-oil: 0.2033±0.0300 label_coffee: 0.1000±0.1090
label_livestock: 0.1667±0.1472
Macro-averaged Specificity: 0.9494±0.0044
label_nat-gas: 0.9854±0.0976 label_crude: 0.9753±0.0950 label_grain:
0.8518±0.0874 label_corn: 0.9040±0.0872 label_wheat: 0.7887±0.0756
label_acq: 0.9670±0.0962 label_gold: 0.9985±0.1000 label_oilseed:
0.9597±0.1014 label_soybean: 0.9968±0.1000 label_sugar: 0.9859±0
.0993 label_bop: 0.9895±0.0992 label_trade: 0.9708±0.0955
label_interest: 0.9745±0.0976 label_money-fx: 0.9413±0.0969
label_ship: 0.9719±0.0971 label_earn: 0.9828±0.0985 label_money-
supply: 0.9930±0.1000 label_dlr: 0.7939±0.0769 label_gnp: 0.9896±0
.0993 label_veg-oil: 0.8691±0.0942 label_coffee: 0.9977±0.1000
label_livestock: 0.9992±0.1000
Average Precision: 0.8329±0.0255
Coverage: 2.6186±0.2469
OneError: 0.1807±0.0397
IsError: 0.4393±0.0409
ErrorSetSize: 2.0091±0.3863
Ranking Loss: 0.0465±0.0096
Mean Average Precision: 0.5385±0.0336
label_nat-gas: 0.7274±0.1174 label_crude: 0.8587±0.0941 label_grain:
0.9011±0.0906 label_corn: 0.4858±0.0601 label_wheat: 0.7120±0.0572
label_acq: 0.5587±0.0810 label_gold: NaN±NaN label_oilseed: 0.1892
±0.0352 label_soybean: 0.2059±0.0499 label_sugar: 0.1542±0.0415
label_bop: 0.7347±0.0942 label_trade: 0.6908±0.0897 label_interest:
0.8735±0.0997 label_money-fx: 0.9646±0.0962 label_ship: 0.7794±0
.1086 label_earn: 0.2486±0.0481 label_money-supply: NaN±NaN
label_dlr: 0.8134±0.0802 label_gnp: 0.5191±0.0577 label_veg-oil:
0.2867±0.0720 label_coffee: NaN±NaN label_livestock: NaN±NaN
Geometric Mean Average Precision: NaN±NaN

A. Topic Modell Multi-Label Learner Ergebnisse

label_nat-gas: 0.7274±0.1174 label_crude: 0.8587±0.0941 label_grain:
0.9011±0.0906 label_corn: 0.4858±0.0601 label_wheat: 0.7120±0.0572
label_acq: 0.5587±0.0810 label_gold: NaN±NaN label_oilseed: 0.1892
±0.0352 label_soybean: 0.2059±0.0499 label_sugar: 0.1542±0.0415
label_bop: 0.7347±0.0942 label_trade: 0.6908±0.0897 label_interest:
0.8735±0.0997 label_money-fx: 0.9646±0.0962 label_ship: 0.7794±0
.1086 label_earn: 0.2486±0.0481 label_money-supply: NaN±NaN
label_dlr: 0.8134±0.0802 label_gnp: 0.5191±0.0577 label_veg-oil:
0.2867±0.0720 label_coffee: NaN±NaN label_livestock: NaN±NaN
Mean Average Interpolated Precision: 0.5513±0.0326
label_nat-gas: 0.7463±0.1161 label_crude: 0.8493±0.0935 label_grain:
0.9045±0.0897 label_corn: 0.5252±0.0627 label_wheat: 0.7395±0.0613
label_acq: 0.5839±0.0776 label_gold: NaN±NaN label_oilseed: 0.2134
±0.0434 label_soybean: 0.2223±0.0541 label_sugar: 0.1720±0.0493
label_bop: 0.7547±0.0875 label_trade: 0.6953±0.0882 label_interest:
0.8726±0.0966 label_money-fx: 0.9561±0.0950 label_ship: 0.7641±0
.1045 label_earn: 0.2754±0.0520 label_money-supply: NaN±NaN
label_dlr: 0.8263±0.0801 label_gnp: 0.5478±0.0603 label_veg-oil:
0.3048±0.0749 label_coffee: NaN±NaN label_livestock: NaN±NaN
Geometric Mean Average Interpolated Precision: NaN±NaN
label_nat-gas: 0.7463±0.1161 label_crude: 0.8493±0.0935 label_grain:
0.9045±0.0897 label_corn: 0.5252±0.0627 label_wheat: 0.7395±0.0613
label_acq: 0.5839±0.0776 label_gold: NaN±NaN label_oilseed: 0.2134
±0.0434 label_soybean: 0.2223±0.0541 label_sugar: 0.1720±0.0493
label_bop: 0.7547±0.0875 label_trade: 0.6953±0.0882 label_interest:
0.8726±0.0966 label_money-fx: 0.9561±0.0950 label_ship: 0.7641±0
.1045 label_earn: 0.2754±0.0520 label_money-supply: NaN±NaN
label_dlr: 0.8263±0.0801 label_gnp: 0.5478±0.0603 label_veg-oil:
0.3048±0.0749 label_coffee: NaN±NaN label_livestock: NaN±NaN
Micro-averaged AUC: 0.9499±0.0097
Macro-averaged AUC: NaN±NaN
label_nat-gas: 0.9705±0.0986 label_crude: 0.9668±0.0978 label_grain:
0.9583±0.0954 label_corn: 0.8821±0.0920 label_wheat: 0.9241±0.0885
label_acq: 0.9321±0.0882 label_gold: NaN±NaN label_oilseed: 0.7763
±0.0818 label_soybean: 0.8249±0.0821 label_sugar: 0.7767±0.0867
label_bop: 0.9714±0.0943 label_trade: 0.9290±0.0955 label_interest:
0.9639±0.0985 label_money-fx: 0.9829±0.0984 label_ship: 0.9246±0
.1022 label_earn: 0.9345±0.0953 label_money-supply: NaN±NaN
label_dlr: 0.9615±0.0953 label_gnp: 0.9623±0.0897 label_veg-oil:
0.7826±0.0974 label_coffee: NaN±NaN label_livestock: NaN±NaN

A.5. Schwellwert 0,12

ElapsedTime: 70775.616
Hamming Loss: 0.1048±0.0046
Subset Accuracy: 0.0418±0.0191
Example-Based Precision: 0.4976±0.0204
Example-Based Recall: 0.7793±0.0193

A. Topic Modell Multi-Label Learner Ergebnisse

Example-Based F Measure: 0.5978 ± 0.0187
Example-Based Accuracy: 0.4629 ± 0.0183
Example-Based Specificity: 0.9095 ± 0.0039
Micro-averaged Precision: 0.4853 ± 0.0169
Micro-averaged Recall: 0.7681 ± 0.0173
Micro-averaged F-Measure: 0.5947 ± 0.0166
Micro-averaged Specificity: 0.9093 ± 0.0039
Macro-averaged Precision: 0.4766 ± 0.0344
label_nat-gas: 0.8082 ± 0.1256 label_crude: 0.8385 ± 0.0787 label_grain:
0.7848 ± 0.0835 label_corn: 0.4727 ± 0.0716 label_wheat: 0.5311 ± 0.0473
label_acq: 0.4655 ± 0.1212 label_gold: 0.3000 ± 0.2010 label_oilseed:
0.1972 ± 0.0190 label_soybean: 0.0734 ± 0.0052 label_sugar: $0.1250 \pm$
.1141 label_bop: 0.7758 ± 0.0935 label_trade: 0.7238 ± 0.0833
label_interest: 0.8575 ± 0.0728 label_money-fx: 0.8725 ± 0.0834
label_ship: 0.8692 ± 0.1019 label_earn: 0.2917 ± 0.1266 label_money-
supply: 0.0333 ± 0.0099 label_dlr: 0.4690 ± 0.0524 label_gnp: $0.3228 \pm$
.0588 label_veg-oil: 0.1723 ± 0.0285 label_coffee: 0.2500 ± 0.1563
label_livestock: 0.2500 ± 0.1563
Macro-averaged Recall: 0.5731 ± 0.0349
label_nat-gas: 0.7300 ± 0.0643 label_crude: 0.8488 ± 0.0934 label_grain:
0.9844 ± 0.0967 label_corn: 0.5524 ± 0.0770 label_wheat: 0.8229 ± 0.1028
label_acq: 0.3573 ± 0.0683 label_gold: 0.3000 ± 0.2010 label_oilseed:
0.5817 ± 0.0623 label_soybean: 0.9746 ± 0.1026 label_sugar: $0.0400 \pm$
.0238 label_bop: 0.7126 ± 0.0899 label_trade: 0.6210 ± 0.1072
label_interest: 0.7784 ± 0.0839 label_money-fx: 0.9078 ± 0.0834
label_ship: 0.6925 ± 0.0920 label_earn: 0.2567 ± 0.1201 label_money-
supply: 0.0500 ± 0.0223 label_dlr: 0.9847 ± 0.1006 label_gnp: $0.6128 \pm$
.0685 label_veg-oil: 0.3908 ± 0.1260 label_coffee: 0.2500 ± 0.1563
label_livestock: 0.1583 ± 0.0898
Macro-averaged F-Measure: 0.4813 ± 0.0329
label_nat-gas: 0.7536 ± 0.0809 label_crude: 0.8400 ± 0.0827 label_grain:
0.8724 ± 0.0891 label_corn: 0.5018 ± 0.0714 label_wheat: 0.6414 ± 0.0636
label_acq: 0.3466 ± 0.0593 label_gold: 0.3000 ± 0.2010 label_oilseed:
0.2881 ± 0.0269 label_soybean: 0.1360 ± 0.0102 label_sugar: $0.0556 \pm$
.0386 label_bop: 0.7340 ± 0.0842 label_trade: 0.6568 ± 0.0894
label_interest: 0.8091 ± 0.0746 label_money-fx: 0.8889 ± 0.0827
label_ship: 0.7613 ± 0.0921 label_earn: 0.2671 ± 0.1188 label_money-
supply: 0.0400 ± 0.0142 label_dlr: 0.6328 ± 0.0689 label_gnp: $0.4028 \pm$
.0559 label_veg-oil: 0.2278 ± 0.0469 label_coffee: 0.2500 ± 0.1563
label_livestock: 0.1833 ± 0.0991
Macro-averaged Specificity: 0.9072 ± 0.0043
label_nat-gas: 0.9875 ± 0.1001 label_crude: 0.9757 ± 0.0954 label_grain:
0.8507 ± 0.0863 label_corn: 0.8811 ± 0.0927 label_wheat: 0.8200 ± 0.0744
label_acq: 0.9739 ± 0.0987 label_gold: 1.0000 ± 0.1000 label_oilseed:
0.7683 ± 0.0970 label_soybean: 0.2005 ± 0.0192 label_sugar: $0.9947 \pm$
.1001 label_bop: 0.9876 ± 0.0978 label_trade: 0.9685 ± 0.0969
label_interest: 0.9758 ± 0.0951 label_money-fx: 0.9374 ± 0.0932
label_ship: 0.9894 ± 0.0992 label_earn: 0.9864 ± 0.0985 label_money-
supply: 0.9897 ± 0.1003 label_dlr: 0.7966 ± 0.0815 label_gnp: 0.9434 ± 0

A. Topic Modell Multi-Label Learner Ergebnisse

.0975 label_veg-oil: 0.9379±0.0886 label_coffee: 0.9993±0.1000
label_livestock: 0.9934±0.0994
Average Precision: 0.7747±0.0391
Coverage: 3.0475±0.2458
OneError: 0.2714±0.0972
IsError: 0.6027±0.0616
ErrorSetSize: 2.5932±0.3962
Ranking Loss: 0.0583±0.0092
Mean Average Precision: 0.5482±0.0324
label_nat-gas: 0.7213±0.1006 label_crude: 0.8573±0.0821 label_grain:
0.9068±0.0996 label_corn: 0.4916±0.0813 label_wheat: 0.6745±0.0659
label_acq: 0.5906±0.1044 label_gold: NaN±NaN label_oilseed: 0.2980
±0.0278 label_soybean: 0.2565±0.0227 label_sugar: 0.0845±0.0080
label_bop: 0.7655±0.0968 label_trade: 0.6561±0.0980 label_interest:
0.8206±0.0774 label_money-fx: 0.9651±0.0941 label_ship: 0.6911±0
.0975 label_earn: 0.3073±0.0809 label_money-supply: 0.3190±0.1030
label_dlr: 0.7918±0.0848 label_gnp: 0.5348±0.1150 label_veg-oil:
0.3354±0.0928 label_coffee: NaN±NaN label_livestock: NaN±NaN
Geometric Mean Average Precision: NaN±NaN
label_nat-gas: 0.7213±0.1006 label_crude: 0.8573±0.0821 label_grain:
0.9068±0.0996 label_corn: 0.4916±0.0813 label_wheat: 0.6745±0.0659
label_acq: 0.5906±0.1044 label_gold: NaN±NaN label_oilseed: 0.2980
±0.0278 label_soybean: 0.2565±0.0227 label_sugar: 0.0845±0.0080
label_bop: 0.7655±0.0968 label_trade: 0.6561±0.0980 label_interest:
0.8206±0.0774 label_money-fx: 0.9651±0.0941 label_ship: 0.6911±0
.0975 label_earn: 0.3073±0.0809 label_money-supply: 0.3190±0.1030
label_dlr: 0.7918±0.0848 label_gnp: 0.5348±0.1150 label_veg-oil:
0.3354±0.0928 label_coffee: NaN±NaN label_livestock: NaN±NaN
Mean Average Interpolated Precision: 0.5642±0.0301
label_nat-gas: 0.7520±0.0945 label_crude: 0.8565±0.0798 label_grain:
0.9114±0.0981 label_corn: 0.5323±0.0817 label_wheat: 0.7010±0.0699
label_acq: 0.6148±0.1104 label_gold: NaN±NaN label_oilseed: 0.3249
±0.0303 label_soybean: 0.2877±0.0276 label_sugar: 0.0904±0.0088
label_bop: 0.7598±0.0925 label_trade: 0.6773±0.0974 label_interest:
0.8161±0.0783 label_money-fx: 0.9574±0.0933 label_ship: 0.6964±0
.0891 label_earn: 0.3496±0.0874 label_money-supply: 0.3413±0.1104
label_dlr: 0.8082±0.0833 label_gnp: 0.5554±0.1157 label_veg-oil:
0.3588±0.1006 label_coffee: NaN±NaN label_livestock: NaN±NaN
Geometric Mean Average Interpolated Precision: NaN±NaN
label_nat-gas: 0.7520±0.0945 label_crude: 0.8565±0.0798 label_grain:
0.9114±0.0981 label_corn: 0.5323±0.0817 label_wheat: 0.7010±0.0699
label_acq: 0.6148±0.1104 label_gold: NaN±NaN label_oilseed: 0.3249
±0.0303 label_soybean: 0.2877±0.0276 label_sugar: 0.0904±0.0088
label_bop: 0.7598±0.0925 label_trade: 0.6773±0.0974 label_interest:
0.8161±0.0783 label_money-fx: 0.9574±0.0933 label_ship: 0.6964±0
.0891 label_earn: 0.3496±0.0874 label_money-supply: 0.3413±0.1104
label_dlr: 0.8082±0.0833 label_gnp: 0.5554±0.1157 label_veg-oil:
0.3588±0.1006 label_coffee: NaN±NaN label_livestock: NaN±NaN
Micro-averaged AUC: 0.9401±0.0070

A. Topic Modell Multi-Label Learner Ergebnisse

Macro-averaged AUC: NaN±NaN

label_nat-gas: 0.9723±0.0960 label_crude: 0.9716±0.0943 label_grain:
0.9587±0.0983 label_corn: 0.8738±0.0926 label_wheat: 0.9126±0.0902
label_acq: 0.9382±0.0984 label_gold: NaN±NaN label_oilseed: 0.8152
±0.0743 label_soybean: 0.7630±0.0780 label_sugar: 0.6999±0.0693
label_bop: 0.9611±0.0964 label_trade: 0.9312±0.0980 label_interest:
0.9585±0.0959 label_money-fx: 0.9836±0.0973 label_ship: 0.9170±0
.0948 label_earn: 0.9409±0.0922 label_money-supply: 0.8791±0.1276
label_dlr: 0.9594±0.0959 label_gnp: 0.9564±0.0992 label_veg-oil:
0.8003±0.1079 label_coffee: NaN±NaN label_livestock: NaN±NaN

A.6. Schwellwert 0,13

ElapsedTime: 68066.032

Hamming Loss: 0.1047±0.0070

Subset Accuracy: 0.0389±0.0300

Example-Based Precision: 0.4988±0.0231

Example-Based Recall: 0.7777±0.0246

Example-Based F Measure: 0.5982±0.0206

Example-Based Accuracy: 0.4628±0.0236

Example-Based Specificity: 0.9098±0.0064

Micro-averaged Precision: 0.4862±0.0196

Micro-averaged Recall: 0.7663±0.0245

Micro-averaged F-Measure: 0.5947±0.0195

Micro-averaged Specificity: 0.9097±0.0064

Macro-averaged Precision: 0.4762±0.0313

label_nat-gas: 0.7223±0.0932 label_crude: 0.8656±0.0839 label_grain:
0.7870±0.0894 label_corn: 0.4885±0.0721 label_wheat: 0.5199±0.0548
label_acq: 0.4610±0.1294 label_gold: 0.4000±0.2240 label_oilseed:
0.2184±0.0256 label_soybean: 0.0707±0.0052 label_sugar: 0.0583±0
.0136 label_bop: 0.7299±0.1154 label_trade: 0.6506±0.0794
label_interest: 0.8438±0.0786 label_money-fx: 0.8777±0.0799
label_ship: 0.7461±0.1170 label_earn: 0.3083±0.1995 label_money-
supply: 0.2250±0.1506 label_dlr: 0.5293±0.0577 label_gnp: 0.4942±0
.1161 label_veg-oil: 0.1798±0.0292 label_coffee: 0.2000±0.1560
label_livestock: 0.1000±0.0890

Macro-averaged Recall: 0.5774±0.0478

label_nat-gas: 0.7536±0.1020 label_crude: 0.8446±0.0893 label_grain:
0.9834±0.1003 label_corn: 0.6013±0.0811 label_wheat: 0.8047±0.1053
label_acq: 0.4179±0.1004 label_gold: 0.3500±0.1903 label_oilseed:
0.4027±0.0416 label_soybean: 0.9900±0.1009 label_sugar: 0.0867±0
.0402 label_bop: 0.6957±0.1129 label_trade: 0.5481±0.0907
label_interest: 0.8058±0.0940 label_money-fx: 0.9383±0.0929
label_ship: 0.6724±0.0681 label_earn: 0.2133±0.1261 label_money-
supply: 0.1583±0.0898 label_dlr: 0.9467±0.1030 label_gnp: 0.6988±0
.1002 label_veg-oil: 0.4900±0.1330 label_coffee: 0.2000±0.1560
label_livestock: 0.1000±0.0890

Macro-averaged F-Measure: 0.4820±0.0347

A. Topic Modell Multi-Label Learner Ergebnisse

label_nat-gas: 0.7268±0.0902 label_crude: 0.8477±0.0818 label_grain:
0.8728±0.0937 label_corn: 0.5300±0.0706 label_wheat: 0.6255±0.0692
label_acq: 0.3873±0.0872 label_gold: 0.3667±0.1966 label_oilseed:
0.2605±0.0260 label_soybean: 0.1315±0.0102 label_sugar: 0.0614±0
.0153 label_bop: 0.7048±0.1066 label_trade: 0.5816±0.0780
label_interest: 0.8204±0.0833 label_money-fx: 0.9060±0.0852
label_ship: 0.6980±0.0827 label_earn: 0.2107±0.1024 label_money-
supply: 0.1300±0.0384 label_dlr: 0.6750±0.0723 label_gnp: 0.5366±0
.0850 label_veg-oil: 0.2301±0.0409 label_coffee: 0.2000±0.1560
label_livestock: 0.1000±0.0890
Macro-averaged Specificity: 0.9079±0.0063
label_nat-gas: 0.9813±0.0986 label_crude: 0.9777±0.0978 label_grain:
0.8523±0.0908 label_corn: 0.8803±0.0934 label_wheat: 0.8156±0.0760
label_acq: 0.9661±0.0989 label_gold: 1.0000±0.1000 label_oilseed:
0.8382±0.0993 label_soybean: 0.1554±0.0238 label_sugar: 0.9894±0
.0979 label_bop: 0.9845±0.0978 label_trade: 0.9611±0.0953
label_interest: 0.9723±0.0952 label_money-fx: 0.9360±0.0908
label_ship: 0.9741±0.0995 label_earn: 0.9940±0.1001 label_money-
supply: 0.9926±0.0993 label_dlr: 0.8463±0.0839 label_gnp: 0.9627±0
.0983 label_veg-oil: 0.8989±0.0944 label_coffee: 0.9993±0.1000
label_livestock: 0.9955±0.1001
Average Precision: 0.7629±0.0408
Coverage: 3.1772±0.2945
OneError: 0.2714±0.0843
IsError: 0.6393±0.0812
ErrorSetSize: 2.7397±0.4230
Ranking Loss: 0.0614±0.0098
Mean Average Precision: 0.5518±0.0350
label_nat-gas: 0.7641±0.0720 label_crude: 0.8534±0.0759 label_grain:
0.8988±0.1001 label_corn: 0.4660±0.0677 label_wheat: 0.7068±0.0579
label_acq: 0.5287±0.1082 label_gold: NaN±NaN label_oilseed: 0.2902
±0.0226 label_soybean: 0.2741±0.0364 label_sugar: 0.1426±0.0315
label_bop: 0.7616±0.1120 label_trade: 0.6619±0.0910 label_interest:
0.8662±0.0892 label_money-fx: 0.9633±0.0943 label_ship: 0.7323±0
.1073 label_earn: 0.2859±0.0710 label_money-supply: 0.2760±0.0894
label_dlr: 0.8003±0.0932 label_gnp: 0.5545±0.0536 label_veg-oil:
0.3059±0.0789 label_coffee: NaN±NaN label_livestock: NaN±NaN
Geometric Mean Average Precision: NaN±NaN
label_nat-gas: 0.7641±0.0720 label_crude: 0.8534±0.0759 label_grain:
0.8988±0.1001 label_corn: 0.4660±0.0677 label_wheat: 0.7068±0.0579
label_acq: 0.5287±0.1082 label_gold: NaN±NaN label_oilseed: 0.2902
±0.0226 label_soybean: 0.2741±0.0364 label_sugar: 0.1426±0.0315
label_bop: 0.7616±0.1120 label_trade: 0.6619±0.0910 label_interest:
0.8662±0.0892 label_money-fx: 0.9633±0.0943 label_ship: 0.7323±0
.1073 label_earn: 0.2859±0.0710 label_money-supply: 0.2760±0.0894
label_dlr: 0.8003±0.0932 label_gnp: 0.5545±0.0536 label_veg-oil:
0.3059±0.0789 label_coffee: NaN±NaN label_livestock: NaN±NaN
Mean Average Interpolated Precision: 0.5652±0.0357

A. Topic Modell Multi-Label Learner Ergebnisse

label_nat-gas: 0.7754±0.0683 label_crude: 0.8521±0.0730 label_grain:
0.9036±0.0985 label_corn: 0.5089±0.0703 label_wheat: 0.7287±0.0620
label_acq: 0.5537±0.1111 label_gold: NaN±NaN label_oilseed: 0.3203
±0.0243 label_soybean: 0.3051±0.0423 label_sugar: 0.1525±0.0340
label_bop: 0.7643±0.1097 label_trade: 0.6775±0.0908 label_interest:
0.8570±0.0877 label_money-fx: 0.9545±0.0931 label_ship: 0.7316±0
.1002 label_earn: 0.3014±0.0740 label_money-supply: 0.2875±0.0951
label_dlr: 0.8146±0.0899 label_gnp: 0.5853±0.0607 label_veg-oil:
0.3296±0.0793 label_coffee: NaN±NaN label_livestock: NaN±NaN
Geometric Mean Average Interpolated Precision: NaN±NaN
label_nat-gas: 0.7754±0.0683 label_crude: 0.8521±0.0730 label_grain:
0.9036±0.0985 label_corn: 0.5089±0.0703 label_wheat: 0.7287±0.0620
label_acq: 0.5537±0.1111 label_gold: NaN±NaN label_oilseed: 0.3203
±0.0243 label_soybean: 0.3051±0.0423 label_sugar: 0.1525±0.0340
label_bop: 0.7643±0.1097 label_trade: 0.6775±0.0908 label_interest:
0.8570±0.0877 label_money-fx: 0.9545±0.0931 label_ship: 0.7316±0
.1002 label_earn: 0.3014±0.0740 label_money-supply: 0.2875±0.0951
label_dlr: 0.8146±0.0899 label_gnp: 0.5853±0.0607 label_veg-oil:
0.3296±0.0793 label_coffee: NaN±NaN label_livestock: NaN±NaN
Micro-averaged AUC: 0.9358±0.0095
Macro-averaged AUC: NaN±NaN
label_nat-gas: 0.9677±0.0871 label_crude: 0.9682±0.0940 label_grain:
0.9566±0.0981 label_corn: 0.8642±0.0905 label_wheat: 0.9159±0.0882
label_acq: 0.9316±0.0984 label_gold: NaN±NaN label_oilseed: 0.8074
±0.0730 label_soybean: 0.7518±0.0888 label_sugar: 0.7410±0.0885
label_bop: 0.9695±0.0991 label_trade: 0.9211±0.0979 label_interest:
0.9644±0.0980 label_money-fx: 0.9814±0.0978 label_ship: 0.9221±0
.0941 label_earn: 0.9366±0.0989 label_money-supply: 0.8927±0.1098
label_dlr: 0.9552±0.0970 label_gnp: 0.9508±0.0937 label_veg-oil:
0.7904±0.1068 label_coffee: NaN±NaN label_livestock: NaN±NaN

B. Evaluationsergebnisse

B.1. Naive Bayes

B.1.1. Korpus A

Standardoptionen

ElapsedTime: 8367.656
Hamming Loss: 0.0747±0.0078
Subset Accuracy: 0.3127±0.0385
Example-Based Precision: 0.6621±0.0273
Example-Based Recall: 0.8572±0.0241
Example-Based F Measure: 0.7194±0.0249
Example-Based Accuracy: 0.6241±0.0281
Example-Based Specificity: 0.9337±0.0076
Micro-averaged Precision: 0.5792±0.0301
Micro-averaged Recall: 0.8485±0.0237
Micro-averaged F-Measure: 0.6881±0.0258
Micro-averaged Specificity: 0.9336±0.0077
Macro-averaged Precision: 0.5020±0.0281
label_nat-gas: 0.6134±0.0730 label_crude: 0.7742±0.0780 label_grain:
0.7531±0.0808 label_corn: 0.4168±0.0592 label_wheat: 0.5272±0.0486
label_acq: 0.3801±0.0677 label_gold: 0.4491±0.2348 label_oilseed:
0.3845±0.0673 label_soybean: 0.6341±0.0991 label_sugar: 0.2722±0
.0472 label_bop: 0.6308±0.0968 label_trade: 0.5235±0.0771
label_interest: 0.7184±0.0846 label_money-fx: 0.8886±0.0909
label_ship: 0.4410±0.0702 label_earn: 0.2822±0.0523 label_money-
supply: 0.3250±0.0766 label_dlr: 0.6442±0.0602 label_gnp: 0.2460±0
.0486 label_veg-oil: 0.4189±0.0718 label_coffee: 0.4333±0.1546
label_livestock: 0.2883±0.0242
Macro-averaged Recall: 0.7531±0.0485
label_nat-gas: 0.9056±0.0996 label_crude: 0.9127±0.1045 label_grain:
0.9176±0.0948 label_corn: 0.8133±0.0858 label_wheat: 0.8904±0.0849
label_acq: 0.8417±0.0947 label_gold: 0.6250±0.3016 label_oilseed:
0.5788±0.0794 label_soybean: 0.6098±0.1036 label_sugar: 0.4429±0
.0830 label_bop: 0.7555±0.1040 label_trade: 0.8053±0.1110
label_interest: 0.8609±0.0877 label_money-fx: 0.9483±0.0976
label_ship: 0.8281±0.1044 label_earn: 0.7667±0.1887 label_money-
supply: 0.6833±0.1925 label_dlr: 0.8277±0.1001 label_gnp: 0.8967±0
.0948 label_veg-oil: 0.4892±0.0750 label_coffee: 0.4917±0.1598

B. Evaluationsergebnisse

label_livestock: 0.6762±0.1265
Macro-averaged F-Measure: 0.5761±0.0346
label_nat-gas: 0.7195±0.0764 label_crude: 0.8364±0.0886 label_grain:
0.8250±0.0858 label_corn: 0.5462±0.0707 label_wheat: 0.6610±0.0611
label_acq: 0.5101±0.0785 label_gold: 0.5038±0.2449 label_oilseed:
0.4371±0.0608 label_soybean: 0.5955±0.0804 label_sugar: 0.3255±0
.0571 label_bop: 0.6664±0.0910 label_trade: 0.6264±0.0885
label_interest: 0.7779±0.0825 label_money-fx: 0.9165±0.0934
label_ship: 0.5649±0.0810 label_earn: 0.4107±0.0841 label_money-
supply: 0.4152±0.0915 label_dlr: 0.7202±0.0732 label_gnp: 0.3725±0
.0646 label_veg-oil: 0.4325±0.0697 label_coffee: 0.4324±0.1263
label_livestock: 0.3786±0.0311
Macro-averaged Specificity: 0.9304±0.0081
label_nat-gas: 0.9611±0.0945 label_crude: 0.9564±0.0930 label_grain:
0.8436±0.0897 label_corn: 0.8078±0.0913 label_wheat: 0.8086±0.0817
label_acq: 0.9163±0.0979 label_gold: 0.9814±0.1005 label_oilseed:
0.9369±0.0947 label_soybean: 0.9841±0.0985 label_sugar: 0.9608±0
.0941 label_bop: 0.9716±0.0951 label_trade: 0.9097±0.0904
label_interest: 0.9273±0.0967 label_money-fx: 0.9425±0.0961
label_ship: 0.8832±0.0925 label_earn: 0.9467±0.0946 label_money-
supply: 0.9767±0.0986 label_dlr: 0.9175±0.0927 label_gnp: 0.8945±0
.0907 label_veg-oil: 0.9749±0.0962 label_coffee: 0.9869±0.0987
label_livestock: 0.9807±0.0963
Average Precision: 0.8011±0.0128
Coverage: 3.7505±0.2559
OneError: 0.2441±0.0225
IsError: 0.4394±0.0247
ErrorSetSize: 3.5409±0.3919
Ranking Loss: 0.0806±0.0091
Mean Average Precision: 0.6412±0.0437
label_nat-gas: 0.8395±0.1000 label_crude: 0.8647±0.0948 label_grain:
0.8035±0.0912 label_corn: 0.6306±0.0777 label_wheat: 0.6249±0.0616
label_acq: 0.6610±0.0882 label_gold: NaN±NaN label_oilseed: 0.4722
±0.0738 label_soybean: 0.6325±0.0886 label_sugar: 0.3470±0.0647
label_bop: 0.7213±0.0970 label_trade: 0.6419±0.0885 label_interest:
0.8355±0.0955 label_money-fx: 0.9415±0.0913 label_ship: 0.6026±0
.0937 label_earn: 0.5123±0.0898 label_money-supply: NaN±NaN
label_dlr: 0.7864±0.0874 label_gnp: 0.4703±0.0750 label_veg-oil:
0.3926±0.0529 label_coffee: NaN±NaN label_livestock: NaN±NaN
Geometric Mean Average Precision: NaN±NaN
label_nat-gas: 0.8395±0.1000 label_crude: 0.8647±0.0948 label_grain:
0.8035±0.0912 label_corn: 0.6306±0.0777 label_wheat: 0.6249±0.0616
label_acq: 0.6610±0.0882 label_gold: NaN±NaN label_oilseed: 0.4722
±0.0738 label_soybean: 0.6325±0.0886 label_sugar: 0.3470±0.0647
label_bop: 0.7213±0.0970 label_trade: 0.6419±0.0885 label_interest:
0.8355±0.0955 label_money-fx: 0.9415±0.0913 label_ship: 0.6026±0
.0937 label_earn: 0.5123±0.0898 label_money-supply: NaN±NaN
label_dlr: 0.7864±0.0874 label_gnp: 0.4703±0.0750 label_veg-oil:
0.3926±0.0529 label_coffee: NaN±NaN label_livestock: NaN±NaN

B. Evaluationsergebnisse

Mean Average Interpolated Precision: 0.6573±0.0468
label_nat-gas: 0.8547±0.1008 label_crude: 0.8718±0.0987 label_grain:
0.8147±0.0897 label_corn: 0.6504±0.0764 label_wheat: 0.6576±0.0645
label_acq: 0.6863±0.0891 label_gold: NaN±NaN label_oilseed: 0.4912
±0.0800 label_soybean: 0.6559±0.0864 label_sugar: 0.3671±0.0709
label_bop: 0.7278±0.0953 label_trade: 0.6646±0.0894 label_interest:
0.8447±0.0911 label_money-fx: 0.9346±0.0940 label_ship: 0.6287±0
.0897 label_earn: 0.5484±0.0993 label_money-supply: NaN±NaN
label_dlr: 0.7924±0.0885 label_gnp: 0.5059±0.0849 label_veg-oil:
0.4124±0.0537 label_coffee: NaN±NaN label_livestock: NaN±NaN
Geometric Mean Average Interpolated Precision: NaN±NaN
label_nat-gas: 0.8547±0.1008 label_crude: 0.8718±0.0987 label_grain:
0.8147±0.0897 label_corn: 0.6504±0.0764 label_wheat: 0.6576±0.0645
label_acq: 0.6863±0.0891 label_gold: NaN±NaN label_oilseed: 0.4912
±0.0800 label_soybean: 0.6559±0.0864 label_sugar: 0.3671±0.0709
label_bop: 0.7278±0.0953 label_trade: 0.6646±0.0894 label_interest:
0.8447±0.0911 label_money-fx: 0.9346±0.0940 label_ship: 0.6287±0
.0897 label_earn: 0.5484±0.0993 label_money-supply: NaN±NaN
label_dlr: 0.7924±0.0885 label_gnp: 0.5059±0.0849 label_veg-oil:
0.4124±0.0537 label_coffee: NaN±NaN label_livestock: NaN±NaN
Micro-averaged AUC: 0.9270±0.0080
Macro-averaged AUC: NaN±NaN
label_nat-gas: 0.9484±0.0964 label_crude: 0.9589±0.1001 label_grain:
0.9060±0.0955 label_corn: 0.8854±0.0932 label_wheat: 0.8835±0.0862
label_acq: 0.9336±0.0875 label_gold: NaN±NaN label_oilseed: 0.7894
±0.0853 label_soybean: 0.8392±0.0918 label_sugar: 0.7589±0.0922
label_bop: 0.9453±0.0959 label_trade: 0.8924±0.0950 label_interest:
0.9474±0.0975 label_money-fx: 0.9718±0.0988 label_ship: 0.8984±0
.0953 label_earn: 0.8892±0.1195 label_money-supply: NaN±NaN
label_dlr: 0.9269±0.0994 label_gnp: 0.9385±0.0913 label_veg-oil:
0.7728±0.0864 label_coffee: NaN±NaN label_livestock: NaN±NaN

Überwachte Diskretisierung

ElapsedTime: 9960.884
Hamming Loss: 0.0467±0.0031
Subset Accuracy: 0.4134±0.0273
Example-Based Precision: 0.7516±0.0198
Example-Based Recall: 0.8823±0.0242
Example-Based F Measure: 0.7907±0.0195
Example-Based Accuracy: 0.7113±0.0200
Example-Based Specificity: 0.9612±0.0032
Micro-averaged Precision: 0.7087±0.0180
Micro-averaged Recall: 0.8794±0.0239
Micro-averaged F-Measure: 0.7846±0.0146
Micro-averaged Specificity: 0.9612±0.0032
Macro-averaged Precision: 0.6606±0.0369
label_nat-gas: 0.7561±0.0982 label_crude: 0.9266±0.0843 label_grain:
0.8411±0.0795 label_corn: 0.4880±0.0554 label_wheat: 0.6537±0.0676

B. Evaluationsergebnisse

label_acq: 0.6257±0.0576 label_gold: 0.9000±0.1890 label_oilseed:
0.6538±0.0848 label_soybean: 0.9000±0.1140 label_sugar: 0.8000±0
.1560 label_bop: 0.5384±0.0799 label_trade: 0.5156±0.0738
label_interest: 0.8001±0.0843 label_money-fx: 0.9235±0.0905
label_ship: 0.9775±0.0948 label_earn: 0.4190±0.0707 label_money-
supply: 0.2771±0.0489 label_dlr: 0.7328±0.0672 label_gnp: 0.3106±0
.0726 label_veg-oil: 0.7433±0.1134 label_coffee: 0.7000±0.3010
label_livestock: 0.0500±0.0223
Macro-averaged Recall: 0.7740±0.0493
label_nat-gas: 0.8956±0.0946 label_crude: 0.8915±0.0917 label_grain:
0.9486±0.0962 label_corn: 0.9647±0.1015 label_wheat: 0.9726±0.0925
label_acq: 0.8567±0.0549 label_gold: 0.8250±0.2226 label_oilseed:
0.7060±0.1006 label_soybean: 0.7008±0.1289 label_sugar: 0.5345±0
.0614 label_bop: 0.7946±0.1000 label_trade: 0.7525±0.1029
label_interest: 0.8612±0.0956 label_money-fx: 0.9730±0.1002
label_ship: 0.7814±0.0976 label_earn: 0.8517±0.1342 label_money-
supply: 0.7000±0.2066 label_dlr: 0.9259±0.1016 label_gnp: 0.8815±0
.1222 label_veg-oil: 0.5842±0.0789 label_coffee: 0.5250±0.2581
label_livestock: 0.1000±0.0890
Macro-averaged F-Measure: 0.6795±0.0372
label_nat-gas: 0.8115±0.0918 label_crude: 0.9068±0.0865 label_grain:
0.8895±0.0855 label_corn: 0.6453±0.0718 label_wheat: 0.7782±0.0761
label_acq: 0.7141±0.0517 label_gold: 0.8400±0.2078 label_oilseed:
0.6690±0.0864 label_soybean: 0.7617±0.1074 label_sugar: 0.6200±0
.0768 label_bop: 0.6330±0.0843 label_trade: 0.5989±0.0791
label_interest: 0.8260±0.0866 label_money-fx: 0.9473±0.0948
label_ship: 0.8649±0.0960 label_earn: 0.5527±0.0902 label_money-
supply: 0.3721±0.0708 label_dlr: 0.8142±0.0785 label_gnp: 0.4454±0
.0928 label_veg-oil: 0.6187±0.0672 label_coffee: 0.5733±0.2580
label_livestock: 0.0667±0.0396
Macro-averaged Specificity: 0.9589±0.0038
label_nat-gas: 0.9797±0.0985 label_crude: 0.9875±0.0965 label_grain:
0.9067±0.0876 label_corn: 0.8335±0.0872 label_wheat: 0.8732±0.0892
label_acq: 0.9727±0.0969 label_gold: 1.0000±0.1000 label_oilseed:
0.9765±0.0969 label_soybean: 0.9968±0.1000 label_sugar: 0.9969±0
.1000 label_bop: 0.9620±0.0958 label_trade: 0.9097±0.0869
label_interest: 0.9550±0.0961 label_money-fx: 0.9632±0.0961
label_ship: 0.9974±0.0991 label_earn: 0.9702±0.0977 label_money-
supply: 0.9675±0.0955 label_dlr: 0.9384±0.0937 label_gnp: 0.9239±0
.0944 label_veg-oil: 0.9929±0.0993 label_coffee: 1.0000±0.1000
label_livestock: 0.9931±0.0993
Average Precision: 0.8717±0.0137
Coverage: 2.8770±0.2271
OneError: 0.1518±0.0234
IsError: 0.3028±0.0325
ErrorSetSize: 2.1807±0.2358
Ranking Loss: 0.0503±0.0061
Mean Average Precision: 0.7628±0.0362

B. Evaluationsergebnisse

label_nat-gas: 0.8720±0.0968 label_crude: 0.9463±0.0953 label_grain:
0.8934±0.0848 label_corn: 0.8479±0.0989 label_wheat: 0.9003±0.0834
label_acq: 0.7334±0.0862 label_gold: NaN±NaN label_oilseed: 0.6825
±0.1173 label_soybean: 0.8008±0.1140 label_sugar: 0.7015±0.0906
label_bop: 0.6966±0.0967 label_trade: 0.5975±0.0941 label_interest:
0.8733±0.0919 label_money-fx: 0.9710±0.0961 label_ship: 0.9025±0
.0992 label_earn: 0.6642±0.1193 label_money-supply: NaN±NaN
label_dlr: 0.8193±0.0730 label_gnp: 0.5457±0.1041 label_veg-oil:
0.6362±0.1035 label_coffee: NaN±NaN label_livestock: NaN±NaN
Geometric Mean Average Precision: NaN±NaN
label_nat-gas: 0.8720±0.0968 label_crude: 0.9463±0.0953 label_grain:
0.8934±0.0848 label_corn: 0.8479±0.0989 label_wheat: 0.9003±0.0834
label_acq: 0.7334±0.0862 label_gold: NaN±NaN label_oilseed: 0.6825
±0.1173 label_soybean: 0.8008±0.1140 label_sugar: 0.7015±0.0906
label_bop: 0.6966±0.0967 label_trade: 0.5975±0.0941 label_interest:
0.8733±0.0919 label_money-fx: 0.9710±0.0961 label_ship: 0.9025±0
.0992 label_earn: 0.6642±0.1193 label_money-supply: NaN±NaN
label_dlr: 0.8193±0.0730 label_gnp: 0.5457±0.1041 label_veg-oil:
0.6362±0.1035 label_coffee: NaN±NaN label_livestock: NaN±NaN
Mean Average Interpolated Precision: 0.7684±0.0348
label_nat-gas: 0.8685±0.0968 label_crude: 0.9310±0.0916 label_grain:
0.9019±0.0852 label_corn: 0.8653±0.0996 label_wheat: 0.9120±0.0851
label_acq: 0.7543±0.0763 label_gold: NaN±NaN label_oilseed: 0.6923
±0.1139 label_soybean: 0.7976±0.1090 label_sugar: 0.7118±0.0876
label_bop: 0.6944±0.0915 label_trade: 0.6116±0.0935 label_interest:
0.8620±0.0921 label_money-fx: 0.9712±0.0977 label_ship: 0.8881±0
.0959 label_earn: 0.6892±0.1156 label_money-supply: NaN±NaN
label_dlr: 0.8375±0.0760 label_gnp: 0.5713±0.1071 label_veg-oil:
0.6359±0.0973 label_coffee: NaN±NaN label_livestock: NaN±NaN
Geometric Mean Average Interpolated Precision: NaN±NaN
label_nat-gas: 0.8685±0.0968 label_crude: 0.9310±0.0916 label_grain:
0.9019±0.0852 label_corn: 0.8653±0.0996 label_wheat: 0.9120±0.0851
label_acq: 0.7543±0.0763 label_gold: NaN±NaN label_oilseed: 0.6923
±0.1139 label_soybean: 0.7976±0.1090 label_sugar: 0.7118±0.0876
label_bop: 0.6944±0.0915 label_trade: 0.6116±0.0935 label_interest:
0.8620±0.0921 label_money-fx: 0.9712±0.0977 label_ship: 0.8881±0
.0959 label_earn: 0.6892±0.1156 label_money-supply: NaN±NaN
label_dlr: 0.8375±0.0760 label_gnp: 0.5713±0.1071 label_veg-oil:
0.6359±0.0973 label_coffee: NaN±NaN label_livestock: NaN±NaN
Micro-averaged AUC: 0.9527±0.0055
Macro-averaged AUC: NaN±NaN
label_nat-gas: 0.9523±0.0946 label_crude: 0.9695±0.0974 label_grain:
0.9569±0.0953 label_corn: 0.9681±0.0999 label_wheat: 0.9734±0.0958
label_acq: 0.9465±0.0790 label_gold: NaN±NaN label_oilseed: 0.8850
±0.1052 label_soybean: 0.8936±0.1014 label_sugar: 0.8947±0.0806
label_bop: 0.8975±0.0944 label_trade: 0.8653±0.0953 label_interest:
0.9423±0.0956 label_money-fx: 0.9869±0.0993 label_ship: 0.9397±0
.0994 label_earn: 0.9626±0.1020 label_money-supply: NaN±NaN
label_dlr: 0.9547±0.0966 label_gnp: 0.9212±0.1041 label_veg-oil:

B. Evaluationsergebnisse

0.8526±0.0994 label_coffee: NaN±NaN label_livestock: NaN±NaN

Kern dichteschätzer

ElapsedTime: 10474.36
Hamming Loss: 0.0501±0.0061
Subset Accuracy: 0.4279±0.0398
Example-Based Precision: 0.7014±0.0449
Example-Based Recall: 0.6073±0.0409
Example-Based F Measure: 0.6351±0.0421
Example-Based Accuracy: 0.5837±0.0420
Example-Based Specificity: 0.9876±0.0030
Micro-averaged Precision: 0.8377±0.0403
Micro-averaged Recall: 0.5980±0.0398
Micro-averaged F-Measure: 0.6976±0.0391
Micro-averaged Specificity: 0.9876±0.0031
Macro-averaged Precision: 0.6815±0.0785
label_nat-gas: 0.9667±0.1099 label_crude: 0.9557±0.0976 label_grain:
0.7614±0.0810 label_corn: 0.8244±0.0996 label_wheat: 0.7036±0.0737
label_acq: 0.6750±0.1551 label_gold: 0.7000±0.3010 label_oilseed:
0.6250±0.1516 label_soybean: 0.6667±0.1556 label_sugar: 0.4000±0
.3040 label_bop: 0.8000±0.1935 label_trade: 0.7764±0.1359
label_interest: 0.9210±0.1047 label_money-fx: 0.9119±0.0942
label_ship: 1.0000±0.1000 label_earn: 0.3000±0.2610 label_money-
supply: 0.4000±0.2240 label_dlr: 0.8546±0.0708 label_gnp: 0.7000±0
.3010 label_veg-oil: 0.5500±0.3023 label_coffee: 0.4000±0.3040
label_livestock: 0.1000±0.1090
Macro-averaged Recall: 0.3991±0.0609
label_nat-gas: 0.3313±0.0633 label_crude: 0.6954±0.0908 label_grain:
0.9296±0.0963 label_corn: 0.3993±0.0573 label_wheat: 0.7585±0.0705
label_acq: 0.2555±0.0348 label_gold: 0.6250±0.3016 label_oilseed:
0.1632±0.0151 label_soybean: 0.1721±0.0194 label_sugar: 0.1250±0
.0530 label_bop: 0.3148±0.0781 label_trade: 0.2683±0.0563
label_interest: 0.5957±0.0931 label_money-fx: 0.8047±0.1015
label_ship: 0.6586±0.0965 label_earn: 0.0750±0.0351 label_money-
supply: 0.2417±0.1115 label_dlr: 0.6326±0.0781 label_gnp: 0.1975±0
.0498 label_veg-oil: 0.1608±0.0459 label_coffee: 0.2750±0.2031
label_livestock: 0.1000±0.1090
Macro-averaged F-Measure: 0.4682±0.0641
label_nat-gas: 0.4742±0.0880 label_crude: 0.8001±0.0919 label_grain:
0.8360±0.0873 label_corn: 0.5314±0.0725 label_wheat: 0.7247±0.0684
label_acq: 0.3595±0.0599 label_gold: 0.6400±0.2934 label_oilseed:
0.2481±0.0282 label_soybean: 0.2593±0.0353 label_sugar: 0.1852±0
.0947 label_bop: 0.4360±0.1087 label_trade: 0.3860±0.0794
label_interest: 0.7090±0.0975 label_money-fx: 0.8529±0.0974
label_ship: 0.7830±0.1025 label_earn: 0.1200±0.0658 label_money-
supply: 0.2867±0.1340 label_dlr: 0.7213±0.0732 label_gnp: 0.3025±0
.0885 label_veg-oil: 0.2389±0.0831 label_coffee: 0.3067±0.2183
label_livestock: 0.1000±0.1090

B. Evaluationsergebnisse

Macro-averaged Specificity: 0.9848±0.0040
label_nat-gas: 0.9992±0.1000 label_crude: 0.9947±0.0991 label_grain:
0.8471±0.0903 label_corn: 0.9866±0.0992 label_wheat: 0.9226±0.0937
label_acq: 0.9984±0.1000 label_gold: 1.0000±0.1000 label_oilseed:
0.9975±0.1000 label_soybean: 0.9992±0.1000 label_sugar: 0.9992±0
.1000 label_bop: 0.9968±0.1000 label_trade: 0.9915±0.0991
label_interest: 0.9891±0.1001 label_money-fx: 0.9655±0.0972
label_ship: 1.0000±0.1000 label_earn: 0.9992±0.1000 label_money-
supply: 1.0000±0.1000 label_dlr: 0.9800±0.0967 label_gnp: 1.0000±0
.1000 label_veg-oil: 0.9992±0.1000 label_coffee: 1.0000±0.1000
label_livestock: 1.0000±0.1000
Average Precision: 0.7203±0.0367
Coverage: 6.6790±0.7663
OneError: 0.2632±0.0489
IsError: 0.4821±0.0490
ErrorSetSize: 7.5577±1.1444
Ranking Loss: 0.1735±0.0257
Mean Average Precision: 0.4884±0.0538
label_nat-gas: 0.5034±0.1014 label_crude: 0.8364±0.0989 label_grain:
0.8562±0.0801 label_corn: 0.6636±0.0850 label_wheat: 0.7097±0.0746
label_acq: 0.3933±0.0469 label_gold: NaN±NaN label_oilseed: 0.2781
±0.0351 label_soybean: 0.2629±0.0359 label_sugar: 0.2131±0.0731
label_bop: 0.4134±0.0922 label_trade: 0.4346±0.0908 label_interest:
0.7878±0.0813 label_money-fx: 0.9301±0.0872 label_ship: 0.7877±0
.0961 label_earn: 0.2014±0.0634 label_money-supply: NaN±NaN
label_dlr: 0.7124±0.0720 label_gnp: 0.3336±0.0880 label_veg-oil:
0.2792±0.0677 label_coffee: NaN±NaN label_livestock: NaN±NaN
Geometric Mean Average Precision: NaN±NaN
label_nat-gas: 0.5034±0.1014 label_crude: 0.8364±0.0989 label_grain:
0.8562±0.0801 label_corn: 0.6636±0.0850 label_wheat: 0.7097±0.0746
label_acq: 0.3933±0.0469 label_gold: NaN±NaN label_oilseed: 0.2781
±0.0351 label_soybean: 0.2629±0.0359 label_sugar: 0.2131±0.0731
label_bop: 0.4134±0.0922 label_trade: 0.4346±0.0908 label_interest:
0.7878±0.0813 label_money-fx: 0.9301±0.0872 label_ship: 0.7877±0
.0961 label_earn: 0.2014±0.0634 label_money-supply: NaN±NaN
label_dlr: 0.7124±0.0720 label_gnp: 0.3336±0.0880 label_veg-oil:
0.2792±0.0677 label_coffee: NaN±NaN label_livestock: NaN±NaN
Mean Average Interpolated Precision: 0.4980±0.0518
label_nat-gas: 0.5158±0.0961 label_crude: 0.8232±0.0939 label_grain:
0.8671±0.0836 label_corn: 0.6771±0.0780 label_wheat: 0.7263±0.0727
label_acq: 0.4152±0.0417 label_gold: NaN±NaN label_oilseed: 0.3105
±0.0436 label_soybean: 0.2962±0.0378 label_sugar: 0.2301±0.0805
label_bop: 0.4302±0.0892 label_trade: 0.4607±0.0885 label_interest:
0.7710±0.0781 label_money-fx: 0.9092±0.0877 label_ship: 0.7685±0
.0886 label_earn: 0.2181±0.0704 label_money-supply: NaN±NaN
label_dlr: 0.7133±0.0722 label_gnp: 0.3511±0.0895 label_veg-oil:
0.2993±0.0696 label_coffee: NaN±NaN label_livestock: NaN±NaN
Geometric Mean Average Interpolated Precision: NaN±NaN

B. Evaluationsergebnisse

label_nat-gas: 0.5158±0.0961 label_crude: 0.8232±0.0939 label_grain:
0.8671±0.0836 label_corn: 0.6771±0.0780 label_wheat: 0.7263±0.0727
label_acq: 0.4152±0.0417 label_gold: NaN±NaN label_oilseed: 0.3105
±0.0436 label_soybean: 0.2962±0.0378 label_sugar: 0.2301±0.0805
label_bop: 0.4302±0.0892 label_trade: 0.4607±0.0885 label_interest:
0.7710±0.0781 label_money-fx: 0.9092±0.0877 label_ship: 0.7685±0
.0886 label_earn: 0.2181±0.0704 label_money-supply: NaN±NaN
label_dlr: 0.7133±0.0722 label_gnp: 0.3511±0.0895 label_veg-oil:
0.2993±0.0696 label_coffee: NaN±NaN label_livestock: NaN±NaN
Micro-averaged AUC: 0.8378±0.0217
Macro-averaged AUC: NaN±NaN
label_nat-gas: 0.7176±0.0908 label_crude: 0.9001±0.0978 label_grain:
0.9356±0.0946 label_corn: 0.8161±0.0939 label_wheat: 0.8628±0.0816
label_acq: 0.6738±0.0602 label_gold: NaN±NaN label_oilseed: 0.5970
±0.0548 label_soybean: 0.6040±0.0580 label_sugar: 0.5859±0.0723
label_bop: 0.6981±0.0849 label_trade: 0.6706±0.0837 label_interest:
0.8564±0.0890 label_money-fx: 0.9574±0.0974 label_ship: 0.8612±0
.0971 label_earn: 0.5787±0.0697 label_money-supply: NaN±NaN
label_dlr: 0.8282±0.0891 label_gnp: 0.6397±0.0800 label_veg-oil:
0.5893±0.0658 label_coffee: NaN±NaN label_livestock: NaN±NaN

B.1.2. Korpus B

Standardoptionen

ElapsedTime: 9932.354
Hamming Loss: 0.0780±0.0075
Subset Accuracy: 0.3014±0.0436
Example-Based Precision: 0.6506±0.0239
Example-Based Recall: 0.8664±0.0170
Example-Based F Measure: 0.7151±0.0195
Example-Based Accuracy: 0.6163±0.0251
Example-Based Specificity: 0.9298±0.0082
Micro-averaged Precision: 0.5759±0.0295
Micro-averaged Recall: 0.8534±0.0182
Micro-averaged F-Measure: 0.6872±0.0221
Micro-averaged Specificity: 0.9297±0.0082
Macro-averaged Precision: 0.4967±0.0460
label_nat-gas: 0.5931±0.0559 label_crude: 0.7892±0.0645 label_grain:
0.7671±0.0801 label_corn: 0.5156±0.0581 label_wheat: 0.5191±0.0477
label_acq: 0.3123±0.0469 label_gold: 0.6000±0.2390 label_oilseed:
0.4324±0.0352 label_soybean: 0.4769±0.0550 label_sugar: 0.2999±0
.0615 label_bop: 0.5464±0.0894 label_trade: 0.4973±0.0562
label_interest: 0.6677±0.0686 label_money-fx: 0.8927±0.0859
label_ship: 0.4480±0.0560 label_earn: 0.2800±0.0548 label_money-
supply: 0.3767±0.1339 label_dlr: 0.6381±0.0773 label_gnp: 0.2599±0
.0467 label_veg-oil: 0.3517±0.0679 label_coffee: 0.3733±0.1209
label_livestock: 0.2904±0.1172
Macro-averaged Recall: 0.7648±0.0477

B. Evaluationsergebnisse

label_nat-gas: 0.9108±0.0926 label_crude: 0.9288±0.0855 label_grain:
0.9182±0.0911 label_corn: 0.8401±0.0846 label_wheat: 0.8784±0.0871
label_acq: 0.7857±0.1192 label_gold: 0.6167±0.2745 label_oilseed:
0.7339±0.0620 label_soybean: 0.6686±0.1022 label_sugar: 0.5483±0
.1103 label_bop: 0.7527±0.1216 label_trade: 0.8435±0.1042
label_interest: 0.8764±0.1053 label_money-fx: 0.9391±0.1007
label_ship: 0.8653±0.0941 label_earn: 0.8667±0.1527 label_money-
supply: 0.6583±0.2331 label_dlr: 0.7951±0.1053 label_gnp: 0.8826±0
.1205 label_veg-oil: 0.5325±0.1353 label_coffee: 0.5250±0.2158
label_livestock: 0.4583±0.2182
Macro-averaged F-Measure: 0.5767±0.0434
label_nat-gas: 0.7103±0.0652 label_crude: 0.8481±0.0701 label_grain:
0.8355±0.0850 label_corn: 0.6366±0.0672 label_wheat: 0.6497±0.0603
label_acq: 0.4406±0.0679 label_gold: 0.5800±0.2268 label_oilseed:
0.5309±0.0389 label_soybean: 0.5469±0.0675 label_sugar: 0.3640±0
.0667 label_bop: 0.6195±0.0988 label_trade: 0.6202±0.0701
label_interest: 0.7555±0.0817 label_money-fx: 0.9146±0.0923
label_ship: 0.5835±0.0673 label_earn: 0.4073±0.0829 label_money-
supply: 0.4467±0.1443 label_dlr: 0.7059±0.0878 label_gnp: 0.3949±0
.0675 label_veg-oil: 0.4136±0.0891 label_coffee: 0.4143±0.1375
label_livestock: 0.2699±0.0782
Macro-averaged Specificity: 0.9266±0.0086
label_nat-gas: 0.9603±0.0955 label_crude: 0.9614±0.0923 label_grain:
0.8423±0.0854 label_corn: 0.8524±0.0876 label_wheat: 0.8007±0.0748
label_acq: 0.9042±0.0898 label_gold: 0.9963±0.0993 label_oilseed:
0.9057±0.0912 label_soybean: 0.9499±0.0944 label_sugar: 0.9615±0
.0983 label_bop: 0.9558±0.0944 label_trade: 0.8880±0.0882
label_interest: 0.9168±0.0919 label_money-fx: 0.9459±0.0932
label_ship: 0.8828±0.0891 label_earn: 0.9451±0.0918 label_money-
supply: 0.9814±0.0986 label_dlr: 0.9193±0.0942 label_gnp: 0.8964±0
.0911 label_veg-oil: 0.9666±0.0980 label_coffee: 0.9874±0.0986
label_livestock: 0.9651±0.0970
Average Precision: 0.7992±0.0286
Coverage: 3.7332±0.5253
OneError: 0.2537±0.0377
IsError: 0.4589±0.0580
ErrorSetSize: 3.6206±0.7021
Ranking Loss: 0.0779±0.0156
Mean Average Precision: 0.6371±0.0397
label_nat-gas: 0.8551±0.1083 label_crude: 0.8786±0.0728 label_grain:
0.8703±0.0928 label_corn: 0.7111±0.0694 label_wheat: 0.5784±0.0560
label_acq: 0.6734±0.1216 label_gold: NaN±NaN label_oilseed: 0.5788
±0.0470 label_soybean: 0.5844±0.0892 label_sugar: 0.3602±0.0735
label_bop: 0.6743±0.1053 label_trade: 0.5862±0.0614 label_interest:
0.8289±0.1019 label_money-fx: 0.9315±0.0931 label_ship: 0.4970±0
.0526 label_earn: 0.5730±0.1398 label_money-supply: 0.5304±0.1981
label_dlr: 0.7338±0.1099 label_gnp: 0.4857±0.1077 label_veg-oil:
0.4517±0.1193 label_coffee: NaN±NaN label_livestock: NaN±NaN
Geometric Mean Average Precision: NaN±NaN

B. Evaluationsergebnisse

label_nat-gas: 0.8551±0.1083 label_crude: 0.8786±0.0728 label_grain:
0.8703±0.0928 label_corn: 0.7111±0.0694 label_wheat: 0.5784±0.0560
label_acq: 0.6734±0.1216 label_gold: NaN±NaN label_oilseed: 0.5788
±0.0470 label_soybean: 0.5844±0.0892 label_sugar: 0.3602±0.0735
label_bop: 0.6743±0.1053 label_trade: 0.5862±0.0614 label_interest:
0.8289±0.1019 label_money-fx: 0.9315±0.0931 label_ship: 0.4970±0
.0526 label_earn: 0.5730±0.1398 label_money-supply: 0.5304±0.1981
label_dlr: 0.7338±0.1099 label_gnp: 0.4857±0.1077 label_veg-oil:
0.4517±0.1193 label_coffee: NaN±NaN label_livestock: NaN±NaN
Mean Average Interpolated Precision: 0.6536±0.0403
label_nat-gas: 0.8510±0.1057 label_crude: 0.8753±0.0716 label_grain:
0.8700±0.0922 label_corn: 0.7231±0.0686 label_wheat: 0.6196±0.0596
label_acq: 0.6848±0.1169 label_gold: NaN±NaN label_oilseed: 0.5965
±0.0532 label_soybean: 0.6070±0.0887 label_sugar: 0.3812±0.0780
label_bop: 0.6829±0.1065 label_trade: 0.6153±0.0684 label_interest:
0.8413±0.0983 label_money-fx: 0.9290±0.0940 label_ship: 0.5356±0
.0525 label_earn: 0.6096±0.1530 label_money-supply: 0.5342±0.1939
label_dlr: 0.7569±0.1057 label_gnp: 0.5332±0.1094 label_veg-oil:
0.4596±0.1132 label_coffee: NaN±NaN label_livestock: NaN±NaN
Geometric Mean Average Interpolated Precision: NaN±NaN
label_nat-gas: 0.8510±0.1057 label_crude: 0.8753±0.0716 label_grain:
0.8700±0.0922 label_corn: 0.7231±0.0686 label_wheat: 0.6196±0.0596
label_acq: 0.6848±0.1169 label_gold: NaN±NaN label_oilseed: 0.5965
±0.0532 label_soybean: 0.6070±0.0887 label_sugar: 0.3812±0.0780
label_bop: 0.6829±0.1065 label_trade: 0.6153±0.0684 label_interest:
0.8413±0.0983 label_money-fx: 0.9290±0.0940 label_ship: 0.5356±0
.0525 label_earn: 0.6096±0.1530 label_money-supply: 0.5342±0.1939
label_dlr: 0.7569±0.1057 label_gnp: 0.5332±0.1094 label_veg-oil:
0.4596±0.1132 label_coffee: NaN±NaN label_livestock: NaN±NaN
Micro-averaged AUC: 0.9266±0.0130
Macro-averaged AUC: NaN±NaN
label_nat-gas: 0.9570±0.1015 label_crude: 0.9622±0.0892 label_grain:
0.9257±0.0963 label_corn: 0.8945±0.0880 label_wheat: 0.8732±0.0842
label_acq: 0.9078±0.1025 label_gold: NaN±NaN label_oilseed: 0.8429
±0.0736 label_soybean: 0.8599±0.0925 label_sugar: 0.7635±0.1077
label_bop: 0.9048±0.1035 label_trade: 0.9003±0.0967 label_interest:
0.9510±0.0996 label_money-fx: 0.9683±0.0978 label_ship: 0.8920±0
.0871 label_earn: 0.9552±0.1036 label_money-supply: 0.8434±0.1408
label_dlr: 0.9218±0.1006 label_gnp: 0.9140±0.1036 label_veg-oil:
0.7662±0.1001 label_coffee: NaN±NaN label_livestock: NaN±NaN

Überwachte Diskretisierung

ElapsedTime: 11127.464
Hamming Loss: 0.0505±0.0029
Subset Accuracy: 0.3930±0.0379
Example-Based Precision: 0.7369±0.0168
Example-Based Recall: 0.8833±0.0217
Example-Based F Measure: 0.7826±0.0162

B. Evaluationsergebnisse

Example-Based Accuracy: 0.7005 ± 0.0193
Example-Based Specificity: 0.9573 ± 0.0034
Micro-averaged Precision: 0.6965 ± 0.0153
Micro-averaged Recall: 0.8799 ± 0.0220
Micro-averaged F-Measure: 0.7773 ± 0.0116
Micro-averaged Specificity: 0.9573 ± 0.0034
Macro-averaged Precision: 0.6608 ± 0.0269
label_nat-gas: 0.7220 ± 0.0993 label_crude: 0.9342 ± 0.0880 label_grain:
0.8395 ± 0.0899 label_corn: 0.5149 ± 0.0638 label_wheat: 0.6443 ± 0.0588
label_acq: 0.6131 ± 0.0983 label_gold: 0.8500 ± 0.2002 label_oilseed:
0.6494 ± 0.0740 label_soybean: 0.7559 ± 0.1110 label_sugar: $0.7000 \pm$
.1941 label_bop: 0.5410 ± 0.0698 label_trade: 0.4989 ± 0.0568
label_interest: 0.7942 ± 0.0755 label_money-fx: 0.9174 ± 0.0869
label_ship: 0.9800 ± 0.0910 label_earn: 0.4010 ± 0.1127 label_money-
supply: 0.2371 ± 0.0872 label_dlr: 0.7341 ± 0.0815 label_gnp: $0.3244 \pm$
.0629 label_veg-oil: 0.7933 ± 0.1412 label_coffee: 0.7667 ± 0.0479
label_livestock: 0.3250 ± 0.1401
Macro-averaged Recall: 0.7864 ± 0.0598
label_nat-gas: 0.8969 ± 0.0891 label_crude: 0.8915 ± 0.0824 label_grain:
0.9544 ± 0.0968 label_corn: 0.9708 ± 0.1009 label_wheat: 0.9596 ± 0.0948
label_acq: 0.8298 ± 0.1086 label_gold: 0.8167 ± 0.1991 label_oilseed:
0.8055 ± 0.0881 label_soybean: 0.7865 ± 0.1112 label_sugar: $0.4833 \pm$
.1298 label_bop: 0.7959 ± 0.0971 label_trade: 0.7954 ± 0.1095
label_interest: 0.8426 ± 0.0936 label_money-fx: 0.9596 ± 0.0984
label_ship: 0.7331 ± 0.0641 label_earn: 0.8267 ± 0.1301 label_money-
supply: 0.5667 ± 0.2823 label_dlr: 0.9128 ± 0.1011 label_gnp: $0.8967 \pm$
.1159 label_veg-oil: 0.5775 ± 0.0828 label_coffee: 0.7667 ± 0.0479
label_livestock: 0.2333 ± 0.0887
Macro-averaged F-Measure: 0.6837 ± 0.0311
label_nat-gas: 0.7918 ± 0.0907 label_crude: 0.9118 ± 0.0846 label_grain:
0.8923 ± 0.0926 label_corn: 0.6699 ± 0.0783 label_wheat: 0.7690 ± 0.0714
label_acq: 0.6969 ± 0.1011 label_gold: 0.8300 ± 0.1972 label_oilseed:
0.7044 ± 0.0709 label_soybean: 0.7543 ± 0.0991 label_sugar: $0.5095 \pm$
.1038 label_bop: 0.6320 ± 0.0763 label_trade: 0.6075 ± 0.0717
label_interest: 0.8154 ± 0.0822 label_money-fx: 0.9374 ± 0.0919
label_ship: 0.8331 ± 0.0715 label_earn: 0.5043 ± 0.1143 label_money-
supply: 0.3108 ± 0.1211 label_dlr: 0.8116 ± 0.0886 label_gnp: $0.4651 \pm$
.0828 label_veg-oil: 0.6307 ± 0.0773 label_coffee: 0.7433 ± 0.0341
label_livestock: 0.2200 ± 0.0503
Macro-averaged Specificity: 0.9548 ± 0.0032
label_nat-gas: 0.9774 ± 0.0993 label_crude: 0.9916 ± 0.0984 label_grain:
0.8971 ± 0.0920 label_corn: 0.8288 ± 0.0850 label_wheat: 0.8694 ± 0.0825
label_acq: 0.9723 ± 0.0978 label_gold: 0.9993 ± 0.1000 label_oilseed:
0.9568 ± 0.0958 label_soybean: 0.9804 ± 0.1002 label_sugar: $0.9955 \pm$
.1000 label_bop: 0.9565 ± 0.0956 label_trade: 0.8954 ± 0.0891
label_interest: 0.9579 ± 0.0952 label_money-fx: 0.9590 ± 0.0941
label_ship: 0.9984 ± 0.0992 label_earn: 0.9693 ± 0.0986 label_money-
supply: 0.9613 ± 0.0973 label_dlr: 0.9382 ± 0.0954 label_gnp: $0.9187 \pm$
.0954 label_veg-oil: 0.9932 ± 0.1000 label_coffee: 0.9978 ± 0.1000

B. Evaluationsergebnisse

label_livestock: 0.9919±0.0986
Average Precision: 0.8713±0.0188
Coverage: 2.9247±0.4063
OneError: 0.1569±0.0174
IsError: 0.3138±0.0488
ErrorSetSize: 2.1976±0.5514
Ranking Loss: 0.0487±0.0124
Mean Average Precision: 0.7619±0.0322
label_nat-gas: 0.8377±0.1058 label_crude: 0.9410±0.0840 label_grain:
0.9098±0.0949 label_corn: 0.8512±0.1039 label_wheat: 0.8875±0.0741
label_acq: 0.7894±0.1007 label_gold: NaN±NaN label_oilseed: 0.7847
±0.0840 label_soybean: 0.7643±0.0984 label_sugar: 0.6751±0.0809
label_bop: 0.7600±0.0882 label_trade: 0.5995±0.0807 label_interest:
0.8649±0.0955 label_money-fx: 0.9617±0.0940 label_ship: 0.8955±0
.0750 label_earn: 0.6165±0.1494 label_money-supply: 0.5063±0.1970
label_dlr: 0.7941±0.0956 label_gnp: 0.5135±0.0938 label_veg-oil:
0.6302±0.1007 label_coffee: NaN±NaN label_livestock: NaN±NaN
Geometric Mean Average Precision: NaN±NaN
label_nat-gas: 0.8377±0.1058 label_crude: 0.9410±0.0840 label_grain:
0.9098±0.0949 label_corn: 0.8512±0.1039 label_wheat: 0.8875±0.0741
label_acq: 0.7894±0.1007 label_gold: NaN±NaN label_oilseed: 0.7847
±0.0840 label_soybean: 0.7643±0.0984 label_sugar: 0.6751±0.0809
label_bop: 0.7600±0.0882 label_trade: 0.5995±0.0807 label_interest:
0.8649±0.0955 label_money-fx: 0.9617±0.0940 label_ship: 0.8955±0
.0750 label_earn: 0.6165±0.1494 label_money-supply: 0.5063±0.1970
label_dlr: 0.7941±0.0956 label_gnp: 0.5135±0.0938 label_veg-oil:
0.6302±0.1007 label_coffee: NaN±NaN label_livestock: NaN±NaN
Mean Average Interpolated Precision: 0.7687±0.0349
label_nat-gas: 0.8517±0.0993 label_crude: 0.9235±0.0792 label_grain:
0.9105±0.0955 label_corn: 0.8563±0.0975 label_wheat: 0.8957±0.0788
label_acq: 0.7913±0.1010 label_gold: NaN±NaN label_oilseed: 0.7853
±0.0858 label_soybean: 0.7729±0.0944 label_sugar: 0.6786±0.0824
label_bop: 0.7694±0.0899 label_trade: 0.6270±0.0875 label_interest:
0.8460±0.0907 label_money-fx: 0.9633±0.0949 label_ship: 0.8814±0
.0775 label_earn: 0.6338±0.1477 label_money-supply: 0.5220±0.2005
label_dlr: 0.8178±0.0911 label_gnp: 0.5583±0.0973 label_veg-oil:
0.6273±0.0924 label_coffee: NaN±NaN label_livestock: NaN±NaN
Geometric Mean Average Interpolated Precision: NaN±NaN
label_nat-gas: 0.8517±0.0993 label_crude: 0.9235±0.0792 label_grain:
0.9105±0.0955 label_corn: 0.8563±0.0975 label_wheat: 0.8957±0.0788
label_acq: 0.7913±0.1010 label_gold: NaN±NaN label_oilseed: 0.7853
±0.0858 label_soybean: 0.7729±0.0944 label_sugar: 0.6786±0.0824
label_bop: 0.7694±0.0899 label_trade: 0.6270±0.0875 label_interest:
0.8460±0.0907 label_money-fx: 0.9633±0.0949 label_ship: 0.8814±0
.0775 label_earn: 0.6338±0.1477 label_money-supply: 0.5220±0.2005
label_dlr: 0.8178±0.0911 label_gnp: 0.5583±0.0973 label_veg-oil:
0.6273±0.0924 label_coffee: NaN±NaN label_livestock: NaN±NaN
Micro-averaged AUC: 0.9529±0.0109
Macro-averaged AUC: NaN±NaN

B. Evaluationsergebnisse

label_nat-gas: 0.9546±0.0933 label_crude: 0.9678±0.0891 label_grain:
0.9594±0.0978 label_corn: 0.9624±0.0987 label_wheat: 0.9619±0.0942
label_acq: 0.9578±0.1009 label_gold: NaN±NaN label_oilseed: 0.9333
±0.0944 label_soybean: 0.9169±0.0942 label_sugar: 0.9079±0.0790
label_bop: 0.9208±0.1026 label_trade: 0.8792±0.1006 label_interest:
0.9365±0.0969 label_money-fx: 0.9864±0.0986 label_ship: 0.9424±0
.0881 label_earn: 0.9630±0.1024 label_money-supply: 0.7971±0.1524
label_dlr: 0.9499±0.0968 label_gnp: 0.9217±0.1016 label_veg-oil:
0.8445±0.1004 label_coffee: NaN±NaN label_livestock: NaN±NaN

Kerndichteschätzer

ElapsedTime: 11192.966
Hamming Loss: 0.0523±0.0029
Subset Accuracy: 0.4187±0.0281
Example-Based Precision: 0.7007±0.0270
Example-Based Recall: 0.5974±0.0235
Example-Based F Measure: 0.6271±0.0231
Example-Based Accuracy: 0.5740±0.0230
Example-Based Specificity: 0.9886±0.0021
Micro-averaged Precision: 0.8494±0.0258
Micro-averaged Recall: 0.5808±0.0217
Micro-averaged F-Measure: 0.6896±0.0191
Micro-averaged Specificity: 0.9885±0.0021
Macro-averaged Precision: 0.7064±0.0690
label_nat-gas: 0.9333±0.1173 label_crude: 0.9736±0.0900 label_grain:
0.7742±0.0779 label_corn: 0.8606±0.0889 label_wheat: 0.7181±0.0682
label_acq: 0.9000±0.1390 label_gold: 0.6000±0.2040 label_oilseed:
0.8000±0.1804 label_soybean: 0.8250±0.1401 label_sugar: 0.3000±0
.2010 label_bop: 0.9417±0.1136 label_trade: 0.8242±0.1354
label_interest: 0.9106±0.1051 label_money-fx: 0.9400±0.0917
label_ship: 0.9833±0.1025 label_earn: 0.2000±0.1560 label_money-
supply: 0.4000±0.3040 label_dlr: 0.8552±0.0831 label_gnp: 0.7000±0
.1110 label_veg-oil: 0.6000±0.3240 label_coffee: 0.3000±0.2010
label_livestock: 0.2000±0.1560
Macro-averaged Recall: 0.3921±0.0492
label_nat-gas: 0.3531±0.0235 label_crude: 0.6692±0.0661 label_grain:
0.9218±0.0990 label_corn: 0.3993±0.0467 label_wheat: 0.7239±0.0771
label_acq: 0.2712±0.0304 label_gold: 0.4833±0.1791 label_oilseed:
0.1989±0.0396 label_soybean: 0.1687±0.0271 label_sugar: 0.0933±0
.0215 label_bop: 0.3585±0.0375 label_trade: 0.3201±0.0607
label_interest: 0.5835±0.0705 label_money-fx: 0.8040±0.0847
label_ship: 0.6420±0.0695 label_earn: 0.1167±0.0878 label_money-
supply: 0.1167±0.0443 label_dlr: 0.6031±0.0524 label_gnp: 0.2119±0
.0173 label_veg-oil: 0.1375±0.0390 label_coffee: 0.2500±0.1563
label_livestock: 0.2000±0.1560
Macro-averaged F-Measure: 0.4702±0.0515
label_nat-gas: 0.5031±0.0376 label_crude: 0.7912±0.0751 label_grain:
0.8409±0.0867 label_corn: 0.5399±0.0618 label_wheat: 0.7169±0.0696

B. Evaluationsergebnisse

label_acq: 0.3931±0.0483 label_gold: 0.5167±0.1758 label_oilseed:
0.3077±0.0651 label_soybean: 0.2677±0.0446 label_sugar: 0.1405±0
.0471 label_bop: 0.5080±0.0542 label_trade: 0.4490±0.0789
label_interest: 0.7070±0.0833 label_money-fx: 0.8652±0.0875
label_ship: 0.7751±0.0820 label_earn: 0.1286±0.0900 label_money-
supply: 0.1800±0.0848 label_dlr: 0.7049±0.0628 label_gnp: 0.3210±0
.0349 label_veg-oil: 0.2208±0.0741 label_coffee: 0.2667±0.1662
label_livestock: 0.2000±0.1560
Macro-averaged Specificity: 0.9858±0.0027
label_nat-gas: 0.9985±0.1000 label_crude: 0.9975±0.0992 label_grain:
0.8497±0.0810 label_corn: 0.9877±0.0974 label_wheat: 0.9299±0.0904
label_acq: 0.9985±0.1000 label_gold: 1.0000±0.1000 label_oilseed:
0.9976±0.0992 label_soybean: 0.9985±0.0992 label_sugar: 0.9992±0
.1000 label_bop: 0.9985±0.1000 label_trade: 0.9901±0.1001
label_interest: 0.9894±0.1000 label_money-fx: 0.9763±0.0970
label_ship: 0.9992±0.1000 label_earn: 1.0000±0.1000 label_money-
supply: 0.9993±0.1000 label_dlr: 0.9809±0.0975 label_gnp: 0.9984±0
.1000 label_veg-oil: 0.9992±0.1000 label_coffee: 1.0000±0.1000
label_livestock: 1.0000±0.1000
Average Precision: 0.7168±0.0282
Coverage: 6.8920±0.5394
OneError: 0.2580±0.0442
IsError: 0.4948±0.0426
ErrorSetSize: 8.1030±0.7222
Ranking Loss: 0.1767±0.0165
Mean Average Precision: 0.4955±0.0367
label_nat-gas: 0.5218±0.0693 label_crude: 0.8609±0.0780 label_grain:
0.8924±0.0937 label_corn: 0.6676±0.0721 label_wheat: 0.7007±0.0801
label_acq: 0.3931±0.0423 label_gold: NaN±NaN label_oilseed: 0.3487
±0.0348 label_soybean: 0.3217±0.0534 label_sugar: 0.1536±0.0375
label_bop: 0.4687±0.0469 label_trade: 0.4647±0.0852 label_interest:
0.7577±0.0985 label_money-fx: 0.9524±0.0916 label_ship: 0.7876±0
.0865 label_earn: 0.2559±0.1063 label_money-supply: 0.2153±0.0586
label_dlr: 0.6955±0.0645 label_gnp: 0.3933±0.0592 label_veg-oil:
0.2257±0.0596 label_coffee: NaN±NaN label_livestock: NaN±NaN
Geometric Mean Average Precision: NaN±NaN
label_nat-gas: 0.5218±0.0693 label_crude: 0.8609±0.0780 label_grain:
0.8924±0.0937 label_corn: 0.6676±0.0721 label_wheat: 0.7007±0.0801
label_acq: 0.3931±0.0423 label_gold: NaN±NaN label_oilseed: 0.3487
±0.0348 label_soybean: 0.3217±0.0534 label_sugar: 0.1536±0.0375
label_bop: 0.4687±0.0469 label_trade: 0.4647±0.0852 label_interest:
0.7577±0.0985 label_money-fx: 0.9524±0.0916 label_ship: 0.7876±0
.0865 label_earn: 0.2559±0.1063 label_money-supply: 0.2153±0.0586
label_dlr: 0.6955±0.0645 label_gnp: 0.3933±0.0592 label_veg-oil:
0.2257±0.0596 label_coffee: NaN±NaN label_livestock: NaN±NaN
Mean Average Interpolated Precision: 0.5069±0.0375
label_nat-gas: 0.5438±0.0713 label_crude: 0.8421±0.0742 label_grain:
0.8856±0.0915 label_corn: 0.6718±0.0688 label_wheat: 0.7142±0.0781
label_acq: 0.4337±0.0456 label_gold: NaN±NaN label_oilseed: 0.3740

B. Evaluationsergebnisse

± 0.0391 label_soybean: 0.3525 ± 0.0614 label_sugar: 0.1643 ± 0.0398
label_bop: 0.4782 ± 0.0474 label_trade: 0.4829 ± 0.0833 label_interest:
0.7577 ± 0.0938 label_money-fx: 0.9389 ± 0.0929 label_ship: 0.7701 ± 0
.0835 label_earn: 0.2706 ± 0.1097 label_money-supply: 0.2441 ± 0.0732
label_dlr: 0.7016 ± 0.0648 label_gnp: 0.4165 ± 0.0582 label_veg-oil:
 0.2552 ± 0.0648 label_coffee: NaN±NaN label_livestock: NaN±NaN
Geometric Mean Average Interpolated Precision: NaN±NaN
label_nat-gas: 0.5438 ± 0.0713 label_crude: 0.8421 ± 0.0742 label_grain:
 0.8856 ± 0.0915 label_corn: 0.6718 ± 0.0688 label_wheat: 0.7142 ± 0.0781
label_acq: 0.4337 ± 0.0456 label_gold: NaN±NaN label_oilseed: 0.3740
 ± 0.0391 label_soybean: 0.3525 ± 0.0614 label_sugar: 0.1643 ± 0.0398
label_bop: 0.4782 ± 0.0474 label_trade: 0.4829 ± 0.0833 label_interest:
0.7577 ± 0.0938 label_money-fx: 0.9389 ± 0.0929 label_ship: 0.7701 ± 0
.0835 label_earn: 0.2706 ± 0.1097 label_money-supply: 0.2441 ± 0.0732
label_dlr: 0.7016 ± 0.0648 label_gnp: 0.4165 ± 0.0582 label_veg-oil:
 0.2552 ± 0.0648 label_coffee: NaN±NaN label_livestock: NaN±NaN
Micro-averaged AUC: 0.8310 ± 0.0113
Macro-averaged AUC: NaN±NaN
label_nat-gas: 0.7276 ± 0.0854 label_crude: 0.9075 ± 0.0891 label_grain:
 0.9425 ± 0.0964 label_corn: 0.7921 ± 0.0781 label_wheat: 0.8628 ± 0.0853
label_acq: 0.6665 ± 0.0635 label_gold: NaN±NaN label_oilseed: 0.6349
 ± 0.0627 label_soybean: 0.6281 ± 0.0723 label_sugar: 0.5460 ± 0.0554
label_bop: 0.6928 ± 0.0665 label_trade: 0.6835 ± 0.0891 label_interest:
0.8510 ± 0.0952 label_money-fx: 0.9643 ± 0.0959 label_ship: 0.8605 ± 0
.0878 label_earn: 0.6133 ± 0.0807 label_money-supply: 0.5991 ± 0.0701
label_dlr: 0.8223 ± 0.0761 label_gnp: 0.6709 ± 0.0622 label_veg-oil:
 0.5802 ± 0.0657 label_coffee: NaN±NaN label_livestock: NaN±NaN

B.2. SVM

B.2.1. Korpus A

ElapsedTime: 1033.147
Hamming Loss: 0.0218 ± 0.0031
Subset Accuracy: 0.7002 ± 0.0351
Example-Based Precision: 0.8947 ± 0.0222
Example-Based Recall: 0.8460 ± 0.0266
Example-Based F Measure: 0.8592 ± 0.0243
Example-Based Accuracy: 0.8231 ± 0.0262
Example-Based Specificity: 0.9932 ± 0.0014
Micro-averaged Precision: 0.9297 ± 0.0142
Micro-averaged Recall: 0.8381 ± 0.0269
Micro-averaged F-Measure: 0.8813 ± 0.0181
Micro-averaged Specificity: 0.9932 ± 0.0014
Macro-averaged Precision: 0.8421 ± 0.0713
label_nat-gas: 0.9565 ± 0.1043 label_crude: 0.9596 ± 0.0976 label_grain:
 0.9704 ± 0.1003 label_corn: 0.9388 ± 0.1020 label_wheat: 0.9334 ± 0.1014
label_acq: 0.9157 ± 0.1121 label_gold: 0.8000 ± 0.2560 label_oilseed:

B. Evaluationsergebnisse

0.8457±0.1339 label_soybean: 0.9524±0.1107 label_sugar: 0.6500±0.2903 label_bop: 0.8869±0.1165 label_trade: 0.8100±0.1026 label_interest: 0.9173±0.0978 label_money-fx: 0.9523±0.0933 label_ship: 0.9186±0.1067 label_earn: 0.7500±0.2563 label_money-supply: 0.7667±0.2512 label_dlr: 0.8706±0.0912 label_gnp: 0.9306±0.1025 label_veg-oil: 0.9000±0.0740 label_coffee: 0.6000±0.3240 label_livestock: 0.3000±0.2610

Macro-averaged Recall: 0.6734±0.0568

label_nat-gas: 0.8730±0.0826 label_crude: 0.9014±0.1035 label_grain: 0.9553±0.0960 label_corn: 0.9105±0.1075 label_wheat: 0.9621±0.0973 label_acq: 0.6391±0.1118 label_gold: 0.7250±0.2731 label_oilseed: 0.5516±0.0904 label_soybean: 0.5967±0.1160 label_sugar: 0.2726±0.0756 label_bop: 0.7071±0.1093 label_trade: 0.7130±0.1082 label_interest: 0.8681±0.0898 label_money-fx: 0.9684±0.0973 label_ship: 0.7637±0.1058 label_earn: 0.3317±0.0816 label_money-supply: 0.6000±0.1946 label_dlr: 0.8701±0.0893 label_gnp: 0.6632±0.0944 label_veg-oil: 0.3950±0.0565 label_coffee: 0.3833±0.2136 label_livestock: 0.1643±0.1302

Macro-averaged F-Measure: 0.7251±0.0592

label_nat-gas: 0.9101±0.0900 label_crude: 0.9283±0.0997 label_grain: 0.9623±0.0977 label_corn: 0.9208±0.1024 label_wheat: 0.9469±0.0989 label_acq: 0.7178±0.1072 label_gold: 0.7400±0.2616 label_oilseed: 0.6626±0.1065 label_soybean: 0.7044±0.1151 label_sugar: 0.3617±0.1147 label_bop: 0.7791±0.1086 label_trade: 0.7527±0.1029 label_interest: 0.8885±0.0907 label_money-fx: 0.9598±0.0948 label_ship: 0.8267±0.1045 label_earn: 0.4538±0.1236 label_money-supply: 0.6433±0.1946 label_dlr: 0.8665±0.0873 label_gnp: 0.7639±0.0925 label_veg-oil: 0.5294±0.0636 label_coffee: 0.4424±0.2321 label_livestock: 0.1917±0.1486

Macro-averaged Specificity: 0.9925±0.0016

label_nat-gas: 0.9976±0.1000 label_crude: 0.9938±0.0992 label_grain: 0.9830±0.1002 label_corn: 0.9892±0.1001 label_wheat: 0.9828±0.1001 label_acq: 0.9968±0.1000 label_gold: 1.0000±0.1000 label_oilseed: 0.9942±0.1000 label_soybean: 0.9984±0.1000 label_sugar: 0.9992±0.1000 label_bop: 0.9951±0.0992 label_trade: 0.9811±0.0964 label_interest: 0.9835±0.0993 label_money-fx: 0.9780±0.0973 label_ship: 0.9924±0.1001 label_earn: 0.9992±0.1000 label_money-supply: 0.9992±0.1000 label_dlr: 0.9767±0.0985 label_gnp: 0.9976±0.0992 label_veg-oil: 0.9984±0.0992 label_coffee: 1.0000±0.1000 label_livestock: 0.9992±0.1000

Average Precision: 0.8856±0.0189

Coverage: 3.4801±0.3751

OneError: 0.0885±0.0242

IsError: 0.2525±0.0325

ErrorSetSize: 2.8432±0.5381

Ranking Loss: 0.0638±0.0128

Mean Average Precision: 0.7043±0.0440

label_nat-gas: 0.8992±0.0861 label_crude: 0.9392±0.1029 label_grain: 0.9806±0.1004 label_corn: 0.8966±0.1044 label_wheat: 0.9494±0.1027

B. Evaluationsergebnisse

label_acq: 0.7006±0.1170 label_gold: NaN±NaN label_oilseed: 0.6392
±0.1012 label_soybean: 0.6843±0.1142 label_sugar: 0.3110±0.0787
label_bop: 0.7825±0.1330 label_trade: 0.7251±0.1031 label_interest:
0.9048±0.0941 label_money-fx: 0.9689±0.0908 label_ship: 0.8219±0
.0996 label_earn: 0.4733±0.0970 label_money-supply: NaN±NaN
label_dlr: 0.8719±0.0862 label_gnp: 0.7051±0.1116 label_veg-oil:
0.5056±0.0554 label_coffee: NaN±NaN label_livestock: NaN±NaN
Geometric Mean Average Precision: NaN±NaN
label_nat-gas: 0.8992±0.0861 label_crude: 0.9392±0.1029 label_grain:
0.9806±0.1004 label_corn: 0.8966±0.1044 label_wheat: 0.9494±0.1027
label_acq: 0.7006±0.1170 label_gold: NaN±NaN label_oilseed: 0.6392
±0.1012 label_soybean: 0.6843±0.1142 label_sugar: 0.3110±0.0787
label_bop: 0.7825±0.1330 label_trade: 0.7251±0.1031 label_interest:
0.9048±0.0941 label_money-fx: 0.9689±0.0908 label_ship: 0.8219±0
.0996 label_earn: 0.4733±0.0970 label_money-supply: NaN±NaN
label_dlr: 0.8719±0.0862 label_gnp: 0.7051±0.1116 label_veg-oil:
0.5056±0.0554 label_coffee: NaN±NaN label_livestock: NaN±NaN
Mean Average Interpolated Precision: 0.7063±0.0435
label_nat-gas: 0.8892±0.0884 label_crude: 0.9264±0.1025 label_grain:
0.9668±0.1009 label_corn: 0.9111±0.1041 label_wheat: 0.9525±0.1019
label_acq: 0.7114±0.1151 label_gold: NaN±NaN label_oilseed: 0.6441
±0.0994 label_soybean: 0.6977±0.1142 label_sugar: 0.3362±0.0868
label_bop: 0.7704±0.1244 label_trade: 0.7302±0.0978 label_interest:
0.8907±0.0941 label_money-fx: 0.9717±0.0951 label_ship: 0.8013±0
.0911 label_earn: 0.4807±0.0950 label_money-supply: NaN±NaN
label_dlr: 0.8690±0.0877 label_gnp: 0.7030±0.1079 label_veg-oil:
0.5210±0.0537 label_coffee: NaN±NaN label_livestock: NaN±NaN
Geometric Mean Average Interpolated Precision: NaN±NaN
label_nat-gas: 0.8892±0.0884 label_crude: 0.9264±0.1025 label_grain:
0.9668±0.1009 label_corn: 0.9111±0.1041 label_wheat: 0.9525±0.1019
label_acq: 0.7114±0.1151 label_gold: NaN±NaN label_oilseed: 0.6441
±0.0994 label_soybean: 0.6977±0.1142 label_sugar: 0.3362±0.0868
label_bop: 0.7704±0.1244 label_trade: 0.7302±0.0978 label_interest:
0.8907±0.0941 label_money-fx: 0.9717±0.0951 label_ship: 0.8013±0
.0911 label_earn: 0.4807±0.0950 label_money-supply: NaN±NaN
label_dlr: 0.8690±0.0877 label_gnp: 0.7030±0.1079 label_veg-oil:
0.5210±0.0537 label_coffee: NaN±NaN label_livestock: NaN±NaN
Micro-averaged AUC: 0.9307±0.0117
Macro-averaged AUC: NaN±NaN
label_nat-gas: 0.9355±0.0901 label_crude: 0.9593±0.1011 label_grain:
0.9839±0.1002 label_corn: 0.9677±0.1013 label_wheat: 0.9836±0.1003
label_acq: 0.8527±0.0943 label_gold: NaN±NaN label_oilseed: 0.7938
±0.0847 label_soybean: 0.8350±0.0984 label_sugar: 0.6361±0.0751
label_bop: 0.9007±0.1015 label_trade: 0.8549±0.0969 label_interest:
0.9482±0.0958 label_money-fx: 0.9874±0.0990 label_ship: 0.8943±0
.0987 label_earn: 0.7167±0.0832 label_money-supply: NaN±NaN
label_dlr: 0.9414±0.0958 label_gnp: 0.8425±0.0961 label_veg-oil:
0.7092±0.0682 label_coffee: NaN±NaN label_livestock: NaN±NaN

B. Evaluationsergebnisse

B.2.2. Korpus B

ElapsedTime: 1155.161
Hamming Loss: 0.0241±0.0034
Subset Accuracy: 0.6731±0.0602
Example-Based Precision: 0.8940±0.0153
Example-Based Recall: 0.8412±0.0260
Example-Based F Measure: 0.8547±0.0228
Example-Based Accuracy: 0.8146±0.0298
Example-Based Specificity: 0.9925±0.0016
Micro-averaged Precision: 0.9243±0.0157
Micro-averaged Recall: 0.8279±0.0254
Micro-averaged F-Measure: 0.8732±0.0180
Micro-averaged Specificity: 0.9924±0.0016
Macro-averaged Precision: 0.8243±0.0606
label_nat-gas: 0.9314±0.1049 label_crude: 0.9782±0.0916 label_grain:
0.9575±0.0973 label_corn: 0.9320±0.0833 label_wheat: 0.9184±0.0866
label_acq: 0.8740±0.0981 label_gold: 0.7000±0.1610 label_oilseed:
0.8584±0.0750 label_soybean: 0.9225±0.1092 label_sugar: 0.7000±0
.1610 label_bop: 0.9146±0.0935 label_trade: 0.8191±0.0932
label_interest: 0.9145±0.0865 label_money-fx: 0.9480±0.0909
label_ship: 0.9459±0.0897 label_earn: 0.6500±0.2903 label_money-
supply: 0.5167±0.2525 label_dlr: 0.8787±0.0974 label_gnp: 0.9583±0
.1071 label_veg-oil: 0.8167±0.1991 label_coffee: 0.6000±0.3240
label_livestock: 0.4000±0.2240
Macro-averaged Recall: 0.6673±0.0540
label_nat-gas: 0.8614±0.0726 label_crude: 0.8818±0.0846 label_grain:
0.9554±0.0956 label_corn: 0.9253±0.0961 label_wheat: 0.9442±0.0911
label_acq: 0.5966±0.1044 label_gold: 0.5667±0.1412 label_oilseed:
0.5610±0.0491 label_soybean: 0.5688±0.0809 label_sugar: 0.3450±0
.0789 label_bop: 0.8201±0.0893 label_trade: 0.7257±0.0917
label_interest: 0.8654±0.0983 label_money-fx: 0.9549±0.0982
label_ship: 0.7856±0.0828 label_earn: 0.3667±0.1637 label_money-
supply: 0.3083±0.1275 label_dlr: 0.8630±0.0992 label_gnp: 0.6895±0
.1064 label_veg-oil: 0.3792±0.0832 label_coffee: 0.4583±0.2391
label_livestock: 0.2583±0.1440
Macro-averaged F-Measure: 0.7156±0.0502
label_nat-gas: 0.8901±0.0829 label_crude: 0.9244±0.0855 label_grain:
0.9556±0.0957 label_corn: 0.9270±0.0883 label_wheat: 0.9303±0.0881
label_acq: 0.6950±0.0968 label_gold: 0.6133±0.1391 label_oilseed:
0.6645±0.0543 label_soybean: 0.6860±0.0872 label_sugar: 0.4414±0
.0886 label_bop: 0.8585±0.0865 label_trade: 0.7630±0.0877
label_interest: 0.8874±0.0910 label_money-fx: 0.9509±0.0940
label_ship: 0.8559±0.0844 label_earn: 0.4376±0.1813 label_money-
supply: 0.3600±0.1372 label_dlr: 0.8660±0.0942 label_gnp: 0.7676±0
.0889 label_veg-oil: 0.4876±0.1018 label_coffee: 0.4900±0.2509
label_livestock: 0.2900±0.1485
Macro-averaged Specificity: 0.9917±0.0018

B. Evaluationsergebnisse

label_nat-gas: 0.9961±0.1000 label_crude: 0.9966±0.0992 label_grain:
0.9761±0.0979 label_corn: 0.9869±0.0956 label_wheat: 0.9800±0.0964
label_acq: 0.9954±0.0985 label_gold: 1.0000±0.1000 label_oilseed:
0.9913±0.0985 label_soybean: 0.9969±0.1000 label_sugar: 1.0000±0
.1000 label_bop: 0.9953±0.0993 label_trade: 0.9776±0.0986
label_interest: 0.9852±0.0976 label_money-fx: 0.9752±0.0960
label_ship: 0.9942±0.0984 label_earn: 0.9985±0.1000 label_money-
supply: 0.9978±0.0993 label_dlr: 0.9775±0.0993 label_gnp: 0.9985±0
.1000 label_veg-oil: 0.9985±0.1000 label_coffee: 1.0000±0.1000
label_livestock: 0.9993±0.1000

Average Precision: 0.8840±0.0173

Coverage: 3.7009±0.4286

OneError: 0.0880±0.0197

IsError: 0.2682±0.0440

ErrorSetSize: 3.0969±0.5603

Ranking Loss: 0.0654±0.0124

Mean Average Precision: 0.7027±0.0353

label_nat-gas: 0.8798±0.0741 label_crude: 0.9113±0.0823 label_grain:
0.9784±0.0984 label_corn: 0.9348±0.0903 label_wheat: 0.9354±0.0931
label_acq: 0.6574±0.1041 label_gold: NaN±NaN label_oilseed: 0.6029
±0.0571 label_soybean: 0.6998±0.0846 label_sugar: 0.5009±0.0746
label_bop: 0.8116±0.0847 label_trade: 0.7305±0.0857 label_interest:
0.8615±0.0882 label_money-fx: 0.9478±0.0944 label_ship: 0.8323±0
.0799 label_earn: 0.4987±0.1680 label_money-supply: 0.3941±0.1240
label_dlr: 0.8726±0.1021 label_gnp: 0.7197±0.1028 label_veg-oil:
0.4593±0.1127 label_coffee: NaN±NaN label_livestock: NaN±NaN

Geometric Mean Average Precision: NaN±NaN

label_nat-gas: 0.8798±0.0741 label_crude: 0.9113±0.0823 label_grain:
0.9784±0.0984 label_corn: 0.9348±0.0903 label_wheat: 0.9354±0.0931
label_acq: 0.6574±0.1041 label_gold: NaN±NaN label_oilseed: 0.6029
±0.0571 label_soybean: 0.6998±0.0846 label_sugar: 0.5009±0.0746
label_bop: 0.8116±0.0847 label_trade: 0.7305±0.0857 label_interest:
0.8615±0.0882 label_money-fx: 0.9478±0.0944 label_ship: 0.8323±0
.0799 label_earn: 0.4987±0.1680 label_money-supply: 0.3941±0.1240
label_dlr: 0.8726±0.1021 label_gnp: 0.7197±0.1028 label_veg-oil:
0.4593±0.1127 label_coffee: NaN±NaN label_livestock: NaN±NaN

Mean Average Interpolated Precision: 0.7079±0.0342

label_nat-gas: 0.8730±0.0788 label_crude: 0.9000±0.0771 label_grain:
0.9688±0.0945 label_corn: 0.9336±0.0920 label_wheat: 0.9274±0.0899
label_acq: 0.6597±0.1017 label_gold: NaN±NaN label_oilseed: 0.6159
±0.0597 label_soybean: 0.7122±0.0857 label_sugar: 0.5155±0.0721
label_bop: 0.8287±0.0889 label_trade: 0.7280±0.0814 label_interest:
0.8567±0.0857 label_money-fx: 0.9508±0.0961 label_ship: 0.8187±0
.0824 label_earn: 0.5116±0.1628 label_money-supply: 0.4134±0.1306
label_dlr: 0.8799±0.0992 label_gnp: 0.7310±0.0980 label_veg-oil:
0.4723±0.1049 label_coffee: NaN±NaN label_livestock: NaN±NaN

Geometric Mean Average Interpolated Precision: NaN±NaN

label_nat-gas: 0.8730±0.0788 label_crude: 0.9000±0.0771 label_grain:
0.9688±0.0945 label_corn: 0.9336±0.0920 label_wheat: 0.9274±0.0899

B. Evaluationsergebnisse

label_acq: 0.6597±0.1017 label_gold: NaN±NaN label_oilseed: 0.6159
±0.0597 label_soybean: 0.7122±0.0857 label_sugar: 0.5155±0.0721
label_bop: 0.8287±0.0889 label_trade: 0.7280±0.0814 label_interest:
0.8567±0.0857 label_money-fx: 0.9508±0.0961 label_ship: 0.8187±0
.0824 label_earn: 0.5116±0.1628 label_money-supply: 0.4134±0.1306
label_dlr: 0.8799±0.0992 label_gnp: 0.7310±0.0980 label_veg-oil:
0.4723±0.1049 label_coffee: NaN±NaN label_livestock: NaN±NaN
Micro-averaged AUC: 0.9275±0.0086
Macro-averaged AUC: NaN±NaN
label_nat-gas: 0.9346±0.0852 label_crude: 0.9493±0.0892 label_grain:
0.9839±0.0983 label_corn: 0.9752±0.0969 label_wheat: 0.9718±0.0954
label_acq: 0.8321±0.0969 label_gold: NaN±NaN label_oilseed: 0.7916
±0.0714 label_soybean: 0.8359±0.0886 label_sugar: 0.7324±0.0690
label_bop: 0.9237±0.0967 label_trade: 0.8757±0.0934 label_interest:
0.9346±0.0966 label_money-fx: 0.9811±0.0989 label_ship: 0.9099±0
.0922 label_earn: 0.7486±0.0998 label_money-supply: 0.7030±0.0939
label_dlr: 0.9491±0.0963 label_gnp: 0.8604±0.0931 label_veg-oil:
0.7262±0.0884 label_coffee: NaN±NaN label_livestock: NaN±NaN

B.3. SLDA

B.3.1. Korpus A

Standarteinstellungen

ElapsedTime: 61638.236
Hamming Loss: 0.0653±0.0080
Subset Accuracy: 0.2716±0.0380
Example-Based Precision: 0.6602±0.0353
Example-Based Recall: 0.7717±0.0421
Example-Based F Measure: 0.7004±0.0366
Example-Based Accuracy: 0.6085±0.0373
Example-Based Specificity: 0.9533±0.0049
Micro-averaged Precision: 0.6361±0.0355
Micro-averaged Recall: 0.7620±0.0405
Micro-averaged F-Measure: 0.6933±0.0368
Micro-averaged Specificity: 0.9532±0.0049
Macro-averaged Precision: 0.5086±0.0783
label_nat-gas: 0.7226±0.1007 label_crude: 0.8285±0.0934 label_grain:
0.7927±0.0763 label_corn: 0.5068±0.0405 label_wheat: 0.4546±0.0409
label_acq: 0.4467±0.0434 label_gold: 0.5000±0.3250 label_oilseed:
0.0513±0.0291 label_soybean: 0.1000±0.0890 label_sugar: 0.2000±0
.1560 label_bop: 0.8032±0.1307 label_trade: 0.7564±0.0964
label_interest: 0.8619±0.0978 label_money-fx: 0.8743±0.0945
label_ship: 0.8312±0.0978 label_earn: 0.3583±0.2478 label_money-
supply: 0.4500±0.2923 label_dlr: 0.4518±0.0318 label_gnp: 0.8167±0
.1505 label_veg-oil: 0.1819±0.0289 label_coffee: 0.1000±0.1090
label_livestock: 0.1000±0.1090

B. Evaluationsergebnisse

Macro-averaged Recall: 0.5353±0.0690
label_nat-gas: 0.7138±0.1012 label_crude: 0.8476±0.1002 label_grain:
0.9832±0.0954 label_corn: 0.5251±0.0621 label_wheat: 0.9477±0.0792
label_acq: 0.4587±0.0571 label_gold: 0.5000±0.3250 label_oilseed:
0.0354±0.0136 label_soybean: 0.0200±0.0036 label_sugar: 0.0476±0
.0107 label_bop: 0.7332±0.1073 label_trade: 0.5449±0.0795
label_interest: 0.8504±0.0865 label_money-fx: 0.9599±0.0986
label_ship: 0.7514±0.1126 label_earn: 0.2650±0.1271 label_money-
supply: 0.3083±0.1995 label_dlr: 0.9673±0.1014 label_gnp: 0.5540±0
.0920 label_veg-oil: 0.5625±0.0908 label_coffee: 0.1000±0.1090
label_livestock: 0.1000±0.1090
Macro-averaged F-Measure: 0.4924±0.0714
label_nat-gas: 0.7036±0.0914 label_crude: 0.8355±0.0950 label_grain:
0.8757±0.0835 label_corn: 0.5065±0.0459 label_wheat: 0.6120±0.0538
label_acq: 0.4243±0.0342 label_gold: 0.5000±0.3250 label_oilseed:
0.0397±0.0182 label_soybean: 0.0333±0.0099 label_sugar: 0.0750±0
.0251 label_bop: 0.7601±0.1134 label_trade: 0.6200±0.0808
label_interest: 0.8512±0.0877 label_money-fx: 0.9125±0.0944
label_ship: 0.7804±0.0998 label_earn: 0.2792±0.1486 label_money-
supply: 0.3500±0.2158 label_dlr: 0.6118±0.0475 label_gnp: 0.6193±0
.0936 label_veg-oil: 0.2435±0.0351 label_coffee: 0.1000±0.1090
label_livestock: 0.1000±0.1090
Macro-averaged Specificity: 0.9491±0.0051
label_nat-gas: 0.9805±0.0985 label_crude: 0.9717±0.0967 label_grain:
0.8658±0.0859 label_corn: 0.9158±0.0859 label_wheat: 0.7202±0.0773
label_acq: 0.9671±0.0971 label_gold: 1.0000±0.1000 label_oilseed:
0.9723±0.0988 label_soybean: 0.9968±0.1000 label_sugar: 0.9914±0
.1002 label_bop: 0.9903±0.0983 label_trade: 0.9784±0.0974
label_interest: 0.9716±0.0993 label_money-fx: 0.9313±0.0982
label_ship: 0.9821±0.0976 label_earn: 0.9875±0.1002 label_money-
supply: 0.9945±0.1001 label_dlr: 0.7858±0.0738 label_gnp: 0.9945±0
.1000 label_veg-oil: 0.8821±0.1003 label_coffee: 1.0000±0.1000
label_livestock: 1.0000±0.1000
Average Precision: 0.8343±0.0330
Coverage: 2.6889±0.3506
OneError: 0.1724±0.0542
IsError: 0.4302±0.0413
ErrorSetSize: 2.1145±0.5162
Ranking Loss: 0.0488±0.0122
Mean Average Precision: 0.5438±0.0418
label_nat-gas: 0.7611±0.1148 label_crude: 0.8453±0.1027 label_grain:
0.9142±0.0865 label_corn: 0.4588±0.0548 label_wheat: 0.7026±0.0557
label_acq: 0.5002±0.0714 label_gold: NaN±NaN label_oilseed: 0.2022
±0.0380 label_soybean: 0.2060±0.0241 label_sugar: 0.1163±0.0190
label_bop: 0.7372±0.1118 label_trade: 0.6859±0.1025 label_interest:
0.8866±0.0988 label_money-fx: 0.9738±0.0961 label_ship: 0.7647±0
.1038 label_earn: 0.2613±0.0533 label_money-supply: NaN±NaN
label_dlr: 0.8406±0.0824 label_gnp: 0.5915±0.1140 label_veg-oil:
0.2503±0.0298 label_coffee: NaN±NaN label_livestock: NaN±NaN

B. Evaluationsergebnisse

Geometric Mean Average Precision: NaN±NaN
label_nat-gas: 0.7611±0.1148 label_crude: 0.8453±0.1027 label_grain:
0.9142±0.0865 label_corn: 0.4588±0.0548 label_wheat: 0.7026±0.0557
label_acq: 0.5002±0.0714 label_gold: NaN±NaN label_oilseed: 0.2022
±0.0380 label_soybean: 0.2060±0.0241 label_sugar: 0.1163±0.0190
label_bop: 0.7372±0.1118 label_trade: 0.6859±0.1025 label_interest:
0.8866±0.0988 label_money-fx: 0.9738±0.0961 label_ship: 0.7647±0
.1038 label_earn: 0.2613±0.0533 label_money-supply: NaN±NaN
label_dlr: 0.8406±0.0824 label_gnp: 0.5915±0.1140 label_veg-oil:
0.2503±0.0298 label_coffee: NaN±NaN label_livestock: NaN±NaN
Mean Average Interpolated Precision: 0.5557±0.0409
label_nat-gas: 0.7841±0.1122 label_crude: 0.8387±0.1001 label_grain:
0.9152±0.0868 label_corn: 0.4977±0.0604 label_wheat: 0.7304±0.0605
label_acq: 0.5297±0.0693 label_gold: NaN±NaN label_oilseed: 0.2305
±0.0443 label_soybean: 0.2264±0.0282 label_sugar: 0.1344±0.0260
label_bop: 0.7509±0.1033 label_trade: 0.6997±0.0971 label_interest:
0.8805±0.0974 label_money-fx: 0.9668±0.0964 label_ship: 0.7545±0
.0990 label_earn: 0.2843±0.0553 label_money-supply: NaN±NaN
label_dlr: 0.8401±0.0824 label_gnp: 0.5971±0.1128 label_veg-oil:
0.2652±0.0324 label_coffee: NaN±NaN label_livestock: NaN±NaN
Geometric Mean Average Interpolated Precision: NaN±NaN
label_nat-gas: 0.7841±0.1122 label_crude: 0.8387±0.1001 label_grain:
0.9152±0.0868 label_corn: 0.4977±0.0604 label_wheat: 0.7304±0.0605
label_acq: 0.5297±0.0693 label_gold: NaN±NaN label_oilseed: 0.2305
±0.0443 label_soybean: 0.2264±0.0282 label_sugar: 0.1344±0.0260
label_bop: 0.7509±0.1033 label_trade: 0.6997±0.0971 label_interest:
0.8805±0.0974 label_money-fx: 0.9668±0.0964 label_ship: 0.7545±0
.0990 label_earn: 0.2843±0.0553 label_money-supply: NaN±NaN
label_dlr: 0.8401±0.0824 label_gnp: 0.5971±0.1128 label_veg-oil:
0.2652±0.0324 label_coffee: NaN±NaN label_livestock: NaN±NaN
Micro-averaged AUC: 0.9498±0.0128
Macro-averaged AUC: NaN±NaN
label_nat-gas: 0.9665±0.0993 label_crude: 0.9569±0.0997 label_grain:
0.9607±0.0944 label_corn: 0.8673±0.0932 label_wheat: 0.9198±0.0884
label_acq: 0.9308±0.0902 label_gold: NaN±NaN label_oilseed: 0.7915
±0.0934 label_soybean: 0.8144±0.0874 label_sugar: 0.7121±0.0793
label_bop: 0.9640±0.0967 label_trade: 0.9290±0.0974 label_interest:
0.9703±0.0987 label_money-fx: 0.9876±0.0987 label_ship: 0.9216±0
.0999 label_earn: 0.9301±0.0957 label_money-supply: NaN±NaN
label_dlr: 0.9647±0.0973 label_gnp: 0.9634±0.0968 label_veg-oil:
0.8102±0.0820 label_coffee: NaN±NaN label_livestock: NaN±NaN

Topics 100

ElapsedTime: 248387.712
Hamming Loss: 0.0473±0.0062
Subset Accuracy: 0.4806±0.0373
Example-Based Precision: 0.7558±0.0310
Example-Based Recall: 0.7895±0.0327

B. Evaluationsergebnisse

Example-Based F Measure: 0.7625±0.0302
Example-Based Accuracy: 0.6989±0.0323
Example-Based Specificity: 0.9713±0.0041
Micro-averaged Precision: 0.7449±0.0328
Micro-averaged Recall: 0.7796±0.0317
Micro-averaged F-Measure: 0.7617±0.0302
Micro-averaged Specificity: 0.9713±0.0041
Macro-averaged Precision: 0.6314±0.0585
label_nat-gas: 0.8393±0.1021 label_crude: 0.9311±0.0982 label_grain:
0.7693±0.0790 label_corn: 0.7141±0.0824 label_wheat: 0.5599±0.0686
label_acq: 0.5335±0.0905 label_gold: 0.4000±0.3040 label_oilseed:
0.6000±0.2740 label_soybean: 0.8667±0.1916 label_sugar: 0.2500±0
.1563 label_bop: 0.7715±0.1374 label_trade: 0.8704±0.1077
label_interest: 0.9075±0.1058 label_money-fx: 0.8753±0.0884
label_ship: 0.8112±0.1077 label_earn: 0.5800±0.2600 label_money-
supply: 0.4000±0.2540 label_dlr: 0.5724±0.0476 label_gnp: 0.8083±0
.2103 label_veg-oil: 0.5300±0.1825 label_coffee: 0.2000±0.1960
label_livestock: 0.1000±0.0890
Macro-averaged Recall: 0.5501±0.0473
label_nat-gas: 0.8542±0.0796 label_crude: 0.8280±0.0991 label_grain:
0.9906±0.0976 label_corn: 0.7332±0.0748 label_wheat: 0.9453±0.0931
label_acq: 0.4009±0.0471 label_gold: 0.4000±0.3040 label_oilseed:
0.1050±0.0194 label_soybean: 0.3146±0.0831 label_sugar: 0.1167±0
.0323 label_bop: 0.7207±0.1081 label_trade: 0.5442±0.0538
label_interest: 0.8451±0.0787 label_money-fx: 0.9509±0.1005
label_ship: 0.6883±0.1086 label_earn: 0.3467±0.1234 label_money-
supply: 0.2583±0.1448 label_dlr: 0.9738±0.1009 label_gnp: 0.5333±0
.1272 label_veg-oil: 0.4125±0.1336 label_coffee: 0.1250±0.1141
label_livestock: 0.0143±0.0018
Macro-averaged F-Measure: 0.5505±0.0532
label_nat-gas: 0.8326±0.0810 label_crude: 0.8726±0.0959 label_grain:
0.8637±0.0861 label_corn: 0.7183±0.0771 label_wheat: 0.7004±0.0781
label_acq: 0.4406±0.0518 label_gold: 0.4000±0.3040 label_oilseed:
0.1759±0.0410 label_soybean: 0.4446±0.1089 label_sugar: 0.1500±0
.0502 label_bop: 0.7353±0.1153 label_trade: 0.6635±0.0688
label_interest: 0.8692±0.0863 label_money-fx: 0.9104±0.0931
label_ship: 0.7280±0.1025 label_earn: 0.4105±0.1487 label_money-
supply: 0.2733±0.1314 label_dlr: 0.7174±0.0631 label_gnp: 0.6167±0
.1437 label_veg-oil: 0.4240±0.1247 label_coffee: 0.1400±0.1224
label_livestock: 0.0250±0.0056
Macro-averaged Specificity: 0.9674±0.0049
label_nat-gas: 0.9887±0.0993 label_crude: 0.9903±0.0992 label_grain:
0.8434±0.0879 label_corn: 0.9512±0.0961 label_wheat: 0.8177±0.0917
label_acq: 0.9799±0.0985 label_gold: 1.0000±0.1000 label_oilseed:
0.9943±0.1001 label_soybean: 0.9976±0.1000 label_sugar: 0.9977±0
.1000 label_bop: 0.9880±0.0992 label_trade: 0.9907±0.0991
label_interest: 0.9808±0.1003 label_money-fx: 0.9363±0.0948
label_ship: 0.9832±0.0992 label_earn: 0.9961±0.1000 label_money-
supply: 0.9961±0.1000 label_dlr: 0.8680±0.0864 label_gnp: 0.9961±0

B. Evaluationsergebnisse

.1000 label_veg-oil: 0.9883±0.0985 label_coffee: 1.0000±0.1000
label_livestock: 0.9985±0.0992
Average Precision: 0.8574±0.0243
Coverage: 2.4066±0.3623
OneError: 0.1602±0.0296
IsError: 0.3707±0.0479
ErrorSetSize: 1.7415±0.4771
Ranking Loss: 0.0401±0.0114
Mean Average Precision: 0.6409±0.0279
label_nat-gas: 0.8416±0.0791 label_crude: 0.9339±0.0976 label_grain:
0.9269±0.0945 label_corn: 0.6323±0.0931 label_wheat: 0.7811±0.0703
label_acq: 0.5974±0.0619 label_gold: NaN±NaN label_oilseed: 0.3672
±0.0911 label_soybean: 0.4230±0.0995 label_sugar: 0.3719±0.0715
label_bop: 0.7763±0.1058 label_trade: 0.7111±0.0925 label_interest:
0.9228±0.0946 label_money-fx: 0.9709±0.0958 label_ship: 0.7832±0
.1033 label_earn: 0.4035±0.0705 label_money-supply: NaN±NaN
label_dlr: 0.8549±0.0928 label_gnp: 0.6526±0.0706 label_veg-oil:
0.2996±0.0494 label_coffee: NaN±NaN label_livestock: NaN±NaN
Geometric Mean Average Precision: NaN±NaN
label_nat-gas: 0.8416±0.0791 label_crude: 0.9339±0.0976 label_grain:
0.9269±0.0945 label_corn: 0.6323±0.0931 label_wheat: 0.7811±0.0703
label_acq: 0.5974±0.0619 label_gold: NaN±NaN label_oilseed: 0.3672
±0.0911 label_soybean: 0.4230±0.0995 label_sugar: 0.3719±0.0715
label_bop: 0.7763±0.1058 label_trade: 0.7111±0.0925 label_interest:
0.9228±0.0946 label_money-fx: 0.9709±0.0958 label_ship: 0.7832±0
.1033 label_earn: 0.4035±0.0705 label_money-supply: NaN±NaN
label_dlr: 0.8549±0.0928 label_gnp: 0.6526±0.0706 label_veg-oil:
0.2996±0.0494 label_coffee: NaN±NaN label_livestock: NaN±NaN
Mean Average Interpolated Precision: 0.6562±0.0272
label_nat-gas: 0.8631±0.0829 label_crude: 0.9256±0.0955 label_grain:
0.9355±0.0933 label_corn: 0.6555±0.0892 label_wheat: 0.8004±0.0703
label_acq: 0.6163±0.0575 label_gold: NaN±NaN label_oilseed: 0.3934
±0.0947 label_soybean: 0.4695±0.0977 label_sugar: 0.4006±0.0837
label_bop: 0.7902±0.0998 label_trade: 0.7342±0.0892 label_interest:
0.9176±0.0934 label_money-fx: 0.9636±0.0952 label_ship: 0.7741±0
.0998 label_earn: 0.4402±0.0794 label_money-supply: NaN±NaN
label_dlr: 0.8685±0.0872 label_gnp: 0.6782±0.0664 label_veg-oil:
0.3139±0.0539 label_coffee: NaN±NaN label_livestock: NaN±NaN
Geometric Mean Average Interpolated Precision: NaN±NaN
label_nat-gas: 0.8631±0.0829 label_crude: 0.9256±0.0955 label_grain:
0.9355±0.0933 label_corn: 0.6555±0.0892 label_wheat: 0.8004±0.0703
label_acq: 0.6163±0.0575 label_gold: NaN±NaN label_oilseed: 0.3934
±0.0947 label_soybean: 0.4695±0.0977 label_sugar: 0.4006±0.0837
label_bop: 0.7902±0.0998 label_trade: 0.7342±0.0892 label_interest:
0.9176±0.0934 label_money-fx: 0.9636±0.0952 label_ship: 0.7741±0
.0998 label_earn: 0.4402±0.0794 label_money-supply: NaN±NaN
label_dlr: 0.8685±0.0872 label_gnp: 0.6782±0.0664 label_veg-oil:
0.3139±0.0539 label_coffee: NaN±NaN label_livestock: NaN±NaN
Micro-averaged AUC: 0.9641±0.0091

B. Evaluationsergebnisse

Macro-averaged AUC: NaN±NaN

label_nat-gas: 0.9840±0.0964 label_crude: 0.9878±0.0988 label_grain:
0.9702±0.0976 label_corn: 0.9184±0.0962 label_wheat: 0.9453±0.0927
label_acq: 0.9607±0.0908 label_gold: NaN±NaN label_oilseed: 0.8685
±0.0899 label_soybean: 0.9363±0.0983 label_sugar: 0.9076±0.0937
label_bop: 0.9781±0.0986 label_trade: 0.9480±0.0957 label_interest:
0.9800±0.0987 label_money-fx: 0.9865±0.0985 label_ship: 0.9477±0
.1003 label_earn: 0.9688±0.0979 label_money-supply: NaN±NaN
label_dlr: 0.9748±0.0977 label_gnp: 0.9731±0.0942 label_veg-oil:
0.8718±0.0880 label_coffee: NaN±NaN label_livestock: NaN±NaN

B.3.2. Korpus B

Standarteinstellungen

ElapsedTime: 69852.408

Hamming Loss: 0.1074±0.0046

Subset Accuracy: 0.0257±0.0137

Example-Based Precision: 0.4888±0.0138

Example-Based Recall: 0.7866±0.0225

Example-Based F Measure: 0.5947±0.0151

Example-Based Accuracy: 0.4565±0.0157

Example-Based Specificity: 0.9060±0.0033

Micro-averaged Precision: 0.4777±0.0121

Micro-averaged Recall: 0.7739±0.0222

Micro-averaged F-Measure: 0.5907±0.0147

Micro-averaged Specificity: 0.9058±0.0033

Macro-averaged Precision: 0.4876±0.0500

label_nat-gas: 0.7865±0.1321 label_crude: 0.8358±0.0658 label_grain:
0.7922±0.0861 label_corn: 0.4662±0.0610 label_wheat: 0.5115±0.0507
label_acq: 0.6706±0.1363 label_gold: 0.3000±0.2010 label_oilseed:
0.2109±0.0186 label_soybean: 0.0668±0.0059 label_sugar: 0.1254±0
.0860 label_bop: 0.7255±0.1048 label_trade: 0.7190±0.0871
label_interest: 0.8348±0.0790 label_money-fx: 0.8663±0.0780
label_ship: 0.7363±0.0953 label_earn: 0.4833±0.1291 label_money-
supply: 0.1033±0.0284 label_dlr: 0.4952±0.0526 label_gnp: 0.4349±0
.1133 label_veg-oil: 0.1632±0.0288 label_coffee: 0.2000±0.1560
label_livestock: 0.2000±0.1560

Macro-averaged Recall: 0.5896±0.0397

label_nat-gas: 0.7356±0.0990 label_crude: 0.8678±0.0936 label_grain:
0.9855±0.0985 label_corn: 0.5576±0.0746 label_wheat: 0.8348±0.1024
label_acq: 0.4563±0.1011 label_gold: 0.3000±0.2010 label_oilseed:
0.5058±0.0344 label_soybean: 0.9675±0.1044 label_sugar: 0.0733±0
.0132 label_bop: 0.7308±0.0955 label_trade: 0.6086±0.0882
label_interest: 0.8196±0.0898 label_money-fx: 0.9188±0.0947
label_ship: 0.6826±0.0731 label_earn: 0.3233±0.1180 label_money-
supply: 0.2333±0.1512 label_dlr: 0.9742±0.1013 label_gnp: 0.5926±0
.0770 label_veg-oil: 0.4033±0.0821 label_coffee: 0.2000±0.1560
label_livestock: 0.2000±0.1560

B. Evaluationsergebnisse

Macro-averaged F-Measure: 0.4909±0.0366
label_nat-gas: 0.7337±0.0969 label_crude: 0.8467±0.0750 label_grain: 0.8774±0.0914 label_corn: 0.4989±0.0637 label_wheat: 0.6286±0.0646 label_acq: 0.5145±0.1028 label_gold: 0.3000±0.2010 label_oilseed: 0.2915±0.0221 label_soybean: 0.1246±0.0114 label_sugar: 0.0676±0.0121 label_bop: 0.7205±0.0941 label_trade: 0.6504±0.0826 label_interest: 0.8217±0.0802 label_money-fx: 0.8909±0.0851 label_ship: 0.7039±0.0804 label_earn: 0.2919±0.0381 label_money-supply: 0.1333±0.0471 label_dlr: 0.6495±0.0666 label_gnp: 0.4357±0.0642 label_veg-oil: 0.2190±0.0388 label_coffee: 0.2000±0.1560 label_livestock: 0.2000±0.1560
Macro-averaged Specificity: 0.9039±0.0037
label_nat-gas: 0.9853±0.1002 label_crude: 0.9739±0.0937 label_grain: 0.8561±0.0890 label_corn: 0.8811±0.0900 label_wheat: 0.8030±0.0729 label_acq: 0.9853±0.0986 label_gold: 1.0000±0.1000 label_oilseed: 0.8185±0.0944 label_soybean: 0.1298±0.0270 label_sugar: 0.9864±0.1004 label_bop: 0.9830±0.0971 label_trade: 0.9668±0.0962 label_interest: 0.9676±0.0961 label_money-fx: 0.9318±0.0894 label_ship: 0.9740±0.0984 label_earn: 0.9925±0.0993 label_money-supply: 0.9710±0.1007 label_dlr: 0.8107±0.0762 label_gnp: 0.9544±0.0944 label_veg-oil: 0.9182±0.0979 label_coffee: 1.0000±0.1000 label_livestock: 0.9955±0.1000
Average Precision: 0.7526±0.0365
Coverage: 3.1402±0.3208
OneError: 0.3029±0.0822
IsError: 0.6444±0.0686
ErrorSetSize: 2.7695±0.4250
Ranking Loss: 0.0623±0.0097
Mean Average Precision: 0.5513±0.0357
label_nat-gas: 0.7038±0.1015 label_crude: 0.8613±0.0836 label_grain: 0.8896±0.0962 label_corn: 0.4431±0.0612 label_wheat: 0.6388±0.0639 label_acq: 0.6195±0.1169 label_gold: NaN±NaN label_oilseed: 0.3092±0.0368 label_soybean: 0.3070±0.0395 label_sugar: 0.1362±0.0375 label_bop: 0.7577±0.1005 label_trade: 0.6485±0.0678 label_interest: 0.8641±0.0879 label_money-fx: 0.9481±0.0979 label_ship: 0.7243±0.0786 label_earn: 0.3212±0.0831 label_money-supply: 0.3158±0.1012 label_dlr: 0.7966±0.0812 label_gnp: 0.5578±0.0945 label_veg-oil: 0.2555±0.0524 label_coffee: NaN±NaN label_livestock: NaN±NaN
Geometric Mean Average Precision: NaN±NaN
label_nat-gas: 0.7038±0.1015 label_crude: 0.8613±0.0836 label_grain: 0.8896±0.0962 label_corn: 0.4431±0.0612 label_wheat: 0.6388±0.0639 label_acq: 0.6195±0.1169 label_gold: NaN±NaN label_oilseed: 0.3092±0.0368 label_soybean: 0.3070±0.0395 label_sugar: 0.1362±0.0375 label_bop: 0.7577±0.1005 label_trade: 0.6485±0.0678 label_interest: 0.8641±0.0879 label_money-fx: 0.9481±0.0979 label_ship: 0.7243±0.0786 label_earn: 0.3212±0.0831 label_money-supply: 0.3158±0.1012 label_dlr: 0.7966±0.0812 label_gnp: 0.5578±0.0945 label_veg-oil: 0.2555±0.0524 label_coffee: NaN±NaN label_livestock: NaN±NaN
Mean Average Interpolated Precision: 0.5673±0.0345

B. Evaluationsergebnisse

label_nat-gas: 0.7415±0.0932 label_crude: 0.8542±0.0828 label_grain:
0.8968±0.0943 label_corn: 0.4811±0.0641 label_wheat: 0.6660±0.0640
label_acq: 0.6401±0.1155 label_gold: NaN±NaN label_oilseed: 0.3331
±0.0383 label_soybean: 0.3340±0.0448 label_sugar: 0.1460±0.0391
label_bop: 0.7613±0.0970 label_trade: 0.6614±0.0723 label_interest:
0.8572±0.0865 label_money-fx: 0.9467±0.0962 label_ship: 0.7247±0
.0731 label_earn: 0.3598±0.0881 label_money-supply: 0.3357±0.1107
label_dlr: 0.8123±0.0833 label_gnp: 0.5803±0.0950 label_veg-oil:
0.2782±0.0590 label_coffee: NaN±NaN label_livestock: NaN±NaN

Geometric Mean Average Interpolated Precision: NaN±NaN

label_nat-gas: 0.7415±0.0932 label_crude: 0.8542±0.0828 label_grain:
0.8968±0.0943 label_corn: 0.4811±0.0641 label_wheat: 0.6660±0.0640
label_acq: 0.6401±0.1155 label_gold: NaN±NaN label_oilseed: 0.3331
±0.0383 label_soybean: 0.3340±0.0448 label_sugar: 0.1460±0.0391
label_bop: 0.7613±0.0970 label_trade: 0.6614±0.0723 label_interest:
0.8572±0.0865 label_money-fx: 0.9467±0.0962 label_ship: 0.7247±0
.0731 label_earn: 0.3598±0.0881 label_money-supply: 0.3357±0.1107
label_dlr: 0.8123±0.0833 label_gnp: 0.5803±0.0950 label_veg-oil:
0.2782±0.0590 label_coffee: NaN±NaN label_livestock: NaN±NaN

Micro-averaged AUC: 0.9354±0.0085

Macro-averaged AUC: NaN±NaN

label_nat-gas: 0.9702±0.0960 label_crude: 0.9709±0.0953 label_grain:
0.9535±0.0969 label_corn: 0.8574±0.0908 label_wheat: 0.9018±0.0887
label_acq: 0.9526±0.0984 label_gold: NaN±NaN label_oilseed: 0.8207
±0.0785 label_soybean: 0.7766±0.0782 label_sugar: 0.6876±0.0725
label_bop: 0.9689±0.0972 label_trade: 0.9202±0.0950 label_interest:
0.9631±0.0970 label_money-fx: 0.9792±0.0985 label_ship: 0.9196±0
.0876 label_earn: 0.9442±0.0938 label_money-supply: 0.9126±0.1082
label_dlr: 0.9580±0.0957 label_gnp: 0.9488±0.0964 label_veg-oil:
0.7596±0.1072 label_coffee: NaN±NaN label_livestock: NaN±NaN

Topics 100

ElapsedTime: 255809.184

Hamming Loss: 0.0782±0.0070

Subset Accuracy: 0.1451±0.0502

Example-Based Precision: 0.6025±0.0330

Example-Based Recall: 0.8048±0.0226

Example-Based F Measure: 0.6740±0.0270

Example-Based Accuracy: 0.5572±0.0325

Example-Based Specificity: 0.9362±0.0060

Micro-averaged Precision: 0.5808±0.0267

Micro-averaged Recall: 0.7930±0.0218

Micro-averaged F-Measure: 0.6703±0.0236

Micro-averaged Specificity: 0.9361±0.0061

Macro-averaged Precision: 0.5880±0.0634

label_nat-gas: 0.8570±0.1194 label_crude: 0.8852±0.0867 label_grain:
0.7778±0.0819 label_corn: 0.6264±0.0799 label_wheat: 0.5834±0.0582
label_acq: 0.5448±0.0645 label_gold: 0.3000±0.2010 label_oilseed:

B. Evaluationsergebnisse

0.3881±0.0263 label_soybean: 0.0819±0.0062 label_sugar: 0.2000±0.1060 label_bop: 0.8060±0.0935 label_trade: 0.9207±0.1066 label_interest: 0.8751±0.0877 label_money-fx: 0.8817±0.0872 label_ship: 0.9187±0.1058 label_earn: 0.5500±0.1922 label_money-supply: 0.4000±0.2240 label_dlr: 0.6352±0.0743 label_gnp: 0.5163±0.0958 label_veg-oil: 0.6883±0.1714 label_coffee: 0.3000±0.2010 label_livestock: 0.2000±0.1560

Macro-averaged Recall: 0.6034±0.0573

label_nat-gas: 0.8283±0.0546 label_crude: 0.8614±0.0895 label_grain: 0.9875±0.0984 label_corn: 0.7491±0.0869 label_wheat: 0.8748±0.0863 label_acq: 0.3827±0.0623 label_gold: 0.3000±0.2010 label_oilseed: 0.4451±0.0599 label_soybean: 0.9457±0.1088 label_sugar: 0.0733±0.0132 label_bop: 0.7584±0.0857 label_trade: 0.4934±0.0827 label_interest: 0.8363±0.0913 label_money-fx: 0.9612±0.1008 label_ship: 0.7643±0.0987 label_earn: 0.3400±0.1222 label_money-supply: 0.1417±0.0314 label_dlr: 0.9438±0.0951 label_gnp: 0.6937±0.0903 label_veg-oil: 0.3950±0.0740 label_coffee: 0.3000±0.2010 label_livestock: 0.2000±0.1560

Macro-averaged F-Measure: 0.5539±0.0526

label_nat-gas: 0.8288±0.0746 label_crude: 0.8706±0.0860 label_grain: 0.8694±0.0889 label_corn: 0.6762±0.0797 label_wheat: 0.6989±0.0689 label_acq: 0.4303±0.0591 label_gold: 0.3000±0.2010 label_oilseed: 0.3942±0.0303 label_soybean: 0.1499±0.0122 label_sugar: 0.1019±0.0239 label_bop: 0.7710±0.0829 label_trade: 0.6363±0.0926 label_interest: 0.8509±0.0860 label_money-fx: 0.9183±0.0923 label_ship: 0.8277±0.0992 label_earn: 0.3738±0.0984 label_money-supply: 0.2067±0.0635 label_dlr: 0.7551±0.0816 label_gnp: 0.5611±0.0730 label_veg-oil: 0.4649±0.0842 label_coffee: 0.3000±0.2010 label_livestock: 0.2000±0.1560

Macro-averaged Specificity: 0.9337±0.0065

label_nat-gas: 0.9907±0.1001 label_crude: 0.9840±0.0977 label_grain: 0.8438±0.0840 label_corn: 0.9129±0.0941 label_wheat: 0.8487±0.0842 label_acq: 0.9838±0.0977 label_gold: 1.0000±0.1000 label_oilseed: 0.9282±0.0857 label_soybean: 0.3076±0.0314 label_sugar: 0.9977±0.1000 label_bop: 0.9884±0.0978 label_trade: 0.9940±0.1000 label_interest: 0.9774±0.0976 label_money-fx: 0.9373±0.0939 label_ship: 0.9935±0.1000 label_earn: 0.9978±0.1000 label_money-supply: 0.9993±0.1000 label_dlr: 0.8996±0.0924 label_gnp: 0.9726±0.0971 label_veg-oil: 0.9909±0.1001 label_coffee: 1.0000±0.1000 label_livestock: 0.9941±0.1001

Average Precision: 0.8263±0.0293

Coverage: 2.7636±0.2658

OneError: 0.1811±0.0542

IsError: 0.4803±0.0558

ErrorSetSize: 2.1662±0.3942

Ranking Loss: 0.0484±0.0093

Mean Average Precision: 0.6238±0.0274

label_nat-gas: 0.8197±0.0882 label_crude: 0.8752±0.0868 label_grain: 0.9281±0.0988 label_corn: 0.6134±0.0768 label_wheat: 0.7752±0.0777

B. Evaluationsergebnisse

label_acq: 0.6565±0.0776 label_gold: NaN±NaN label_oilseed: 0.4309
±0.0623 label_soybean: 0.3317±0.0448 label_sugar: 0.2551±0.0389
label_bop: 0.8086±0.1027 label_trade: 0.7050±0.0888 label_interest:
0.9109±0.0985 label_money-fx: 0.9747±0.0987 label_ship: 0.7887±0
.0862 label_earn: 0.5078±0.1371 label_money-supply: 0.3165±0.0934
label_dlr: 0.8609±0.0924 label_gnp: 0.6264±0.0830 label_veg-oil:
0.3403±0.0622 label_coffee: NaN±NaN label_livestock: NaN±NaN
Geometric Mean Average Precision: NaN±NaN
label_nat-gas: 0.8197±0.0882 label_crude: 0.8752±0.0868 label_grain:
0.9281±0.0988 label_corn: 0.6134±0.0768 label_wheat: 0.7752±0.0777
label_acq: 0.6565±0.0776 label_gold: NaN±NaN label_oilseed: 0.4309
±0.0623 label_soybean: 0.3317±0.0448 label_sugar: 0.2551±0.0389
label_bop: 0.8086±0.1027 label_trade: 0.7050±0.0888 label_interest:
0.9109±0.0985 label_money-fx: 0.9747±0.0987 label_ship: 0.7887±0
.0862 label_earn: 0.5078±0.1371 label_money-supply: 0.3165±0.0934
label_dlr: 0.8609±0.0924 label_gnp: 0.6264±0.0830 label_veg-oil:
0.3403±0.0622 label_coffee: NaN±NaN label_livestock: NaN±NaN
Mean Average Interpolated Precision: 0.6384±0.0262
label_nat-gas: 0.8352±0.0827 label_crude: 0.8770±0.0840 label_grain:
0.9301±0.0977 label_corn: 0.6444±0.0762 label_wheat: 0.7914±0.0779
label_acq: 0.6851±0.0792 label_gold: NaN±NaN label_oilseed: 0.4554
±0.0620 label_soybean: 0.3631±0.0512 label_sugar: 0.2738±0.0448
label_bop: 0.8050±0.0955 label_trade: 0.7180±0.0889 label_interest:
0.8997±0.0973 label_money-fx: 0.9680±0.0982 label_ship: 0.7887±0
.0833 label_earn: 0.5470±0.1344 label_money-supply: 0.3428±0.1000
label_dlr: 0.8657±0.0907 label_gnp: 0.6640±0.0862 label_veg-oil:
0.3591±0.0613 label_coffee: NaN±NaN label_livestock: NaN±NaN
Geometric Mean Average Interpolated Precision: NaN±NaN
label_nat-gas: 0.8352±0.0827 label_crude: 0.8770±0.0840 label_grain:
0.9301±0.0977 label_corn: 0.6444±0.0762 label_wheat: 0.7914±0.0779
label_acq: 0.6851±0.0792 label_gold: NaN±NaN label_oilseed: 0.4554
±0.0620 label_soybean: 0.3631±0.0512 label_sugar: 0.2738±0.0448
label_bop: 0.8050±0.0955 label_trade: 0.7180±0.0889 label_interest:
0.8997±0.0973 label_money-fx: 0.9680±0.0982 label_ship: 0.7887±0
.0833 label_earn: 0.5470±0.1344 label_money-supply: 0.3428±0.1000
label_dlr: 0.8657±0.0907 label_gnp: 0.6640±0.0862 label_veg-oil:
0.3591±0.0613 label_coffee: NaN±NaN label_livestock: NaN±NaN
Micro-averaged AUC: 0.9530±0.0083
Macro-averaged AUC: NaN±NaN
label_nat-gas: 0.9820±0.0945 label_crude: 0.9794±0.0968 label_grain:
0.9699±0.0983 label_corn: 0.9067±0.0934 label_wheat: 0.9387±0.0918
label_acq: 0.9640±0.0961 label_gold: NaN±NaN label_oilseed: 0.8786
±0.0853 label_soybean: 0.8061±0.0901 label_sugar: 0.8513±0.0872
label_bop: 0.9782±0.0982 label_trade: 0.9433±0.0980 label_interest:
0.9773±0.0992 label_money-fx: 0.9885±0.0994 label_ship: 0.9527±0
.0937 label_earn: 0.9702±0.0981 label_money-supply: 0.9004±0.1051
label_dlr: 0.9703±0.0974 label_gnp: 0.9635±0.0985 label_veg-oil:
0.8548±0.1052 label_coffee: NaN±NaN label_livestock: NaN±NaN

Erklärung

„Ich versichere, dass ich die vorliegende Arbeit selbständig und nur unter Verwendung der angegebenen Quellen und Hilfsmittel angefertigt habe, insbesondere sind wörtliche oder sinngemäße Zitate als solche gekennzeichnet. Mir ist bekannt, dass Zuwiderhandlung auch nachträglich zur Aberkennung des Abschlusses führen kann.“

Ort

Datum

Unterschrift