Fortschritt-Berichte VDI

VDI

Reihe 10

Informatik/
Kommunikation

Herwig Unger,
Mario M. Kubek

Nr. 863

Theory and Application of Text-representing Centroids

FernUniversität in Hagen
Schriften zur Informations- und Kommunikationstechnik

https://doi.org/10.51202/9783186863102-I - Generiert durch IP 216.73.217.60, am 08.05.2026, 00:42:05. © Urheberrechtlich geschützter Inhalt. Ohne gesonderte Erlaubnis ist jede urheberrechtliche Nutzung untersagt, insbesondere die Nutzung des Inhalts im Zusammenhang mit, für oder in KI-Systemen, KI-Modellen oder Generativen Sprachmodellen.

https://doi.org/10.51202/9783186863102-I - Generiert durch IP 216.73.217.60, am 08.05.2026, 00:42:05. © Urheberrechtlich geschützter Inhalt. Ohne gesonderte
Erlaubnis ist jede urheberrechtliche Nutzung untersagt, insbesondere die Nutzung des Inhalts im Zusammenhang mit, für oder in KI-Systemen, KI-Modellen oder Generativen Sprachmodellen.

Theory and Application of Text-representing Centroids

Herwig Unger and Mario M. Kubek

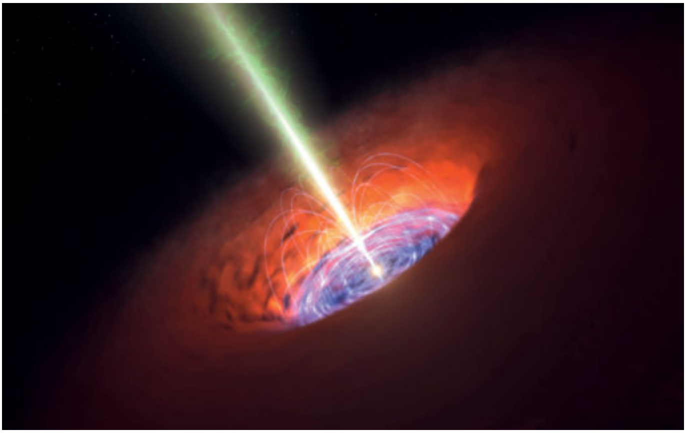

Email: kn.wissenschaftler@fernuni-hagen.de
Website: https://www.fernuni-hagen.de/kn/

https://doi.org/10.51202/9783186863102-I - Generiert durch IP 216.73.217.60, am 08.05.2026, 00:42:05. © Urheberrechtlich geschützter Inhalt. Ohne gesonderte Erlaubnis ist jede urheberrechtliche Nutzung untersagt, insbesondere die Nutzung des Inhalts im Zusammenhang mit, für oder in KI-Systemen, KI-Modellen oder Generativen Sprachmodellen.

https://doi.org/10.51202/9783186863102-I - Generiert durch IP 216.73.217.60, am 08.05.2026, 00:42:05. © Urheberrechtlich geschützter Inhalt. Ohne gesonderte
Erlaubnis ist jede urheberrechtliche Nutzung untersagt, insbesondere die Nutzung des Inhalts im Zusammenhang mit, für oder in KI-Systemen, KI-Modellen oder Generativen Sprachmodellen.

Fortschritt-Berichte VDI

Reihe 10

Informatik/
Kommunikation

Herwig Unger,
Mario M. Kubek

Nr. 863

Theory and Application of Text-representing Centroids

FernUniversität in Hagen
Schriften zur Informations- und Kommunikationstechnik

https://doi.org/10.51202/9783186863102-I - Generiert durch IP 216.73.217.60, am 08.05.2026, 00:42:05. © Urheberrechtlich geschützter Inhalt. Ohne gesonderte Erlaubnis ist jede urheberrechtliche Nutzung untersagt, insbesondere die Nutzung des Inhalts im Zusammenhang mit, für oder in KI-Systemen, KI-Modellen oder Generativen Sprachmodellen.

Herwig Unger, Mario M. Kubek
Theory and Application of Text-representing Centroids
Fortschr.-Ber. VDI Reihe 10 Nr. 863. Düsseldorf: VDI Verlag 2019.
152 Seiten, 49 Bilder, 10 Tabellen.
ISBN 978-3-18-386310-5, ISSN 0178-9627,
€ 57,00/VDI-Mitgliederpreis € 51,30.

Keywords: Text Processing – Text Centroid – Co-occurrence Graph – Spreading Activation – Text Categorisation – Librarian of the Web – P2P-system – Decentralised Search – WebEngine – Web Search Engine

Centroid terms are single, descriptive words that semantically and topically characterise text documents and thus can act as their very compact representation in automated text processing tasks that strongly rely on the semantic similarity of texts. Algorithms to classify and cluster them make use of this information. In this book, the novel, brain- and physicsinspired concept of centroid terms is introduced and deeply discussed. Furthermore, their unique properties and practical usage in major natural language processing and text mining tasks are covered. In this regard, a new graph-based method for their fast calculation is presented as well. In contrast to methods relying on the bag-of-words model, the derived centroid distance measure can uncover a topical relationship between texts even when their wording differs. As centroid terms can also represent short texts, the presented first fully integrated, P2P-based web search engine, called "WebEngine", therefore makes heavy use of centroid terms when interpreting queries and forwarding them to peers with matching documents, represented by their own centroid terms.

Bibliographische Information der Deutschen Bibliothek
Die Deutsche Bibliothek verzeichnet diese Publikation in der Deutschen Nationalbibliographie; detaillierte bibliographische Daten sind im Internet unter www.dnb.de abrufbar.

Bibliographic information published by the Deutsche Bibliothek
(German National Library)
The Deutsche Bibliothek lists this publication in the Deutsche Nationalbibliographie (German National Bibliography); detailed bibliographic data is available via Internet at www.dnb.de.

Schriften zur Informations- und Kommunikationstechnik
Herausgeber:
Wolfgang A. Halang, ehemaliger Lehrstuhl für Informationstechnik
Herwig Unger, Lehrstuhl für Kommunikationstechnik
FernUniversität in Hagen

© VDI Verlag GmbH · Düsseldorf 2019

Alle Rechte, auch das des auszugsweisen Nachdruckes, der auszugsweisen oder vollständigen Wiedergabe (Fotokopie, Mikrokopie), der Speicherung in Datenverarbeitungsanlagen, im Internet und das der Übersetzung, vorbehalten.

Als Manuskript gedruckt. Printed in Germany.

ISSN 0178-9627

ISBN 978-3-18-386310-5

https://doi.org/10.51202/9783186863102-I - Generiert durch IP 216.73.217.60, am 08.05.2026, 00:42:05. © Urheberrechtlich geschützter Inhalt. Ohne gesonderte Erlaubnis ist jede urheberrechtliche Nutzung untersagt, insbesondere die Nutzung des Inhalts im Zusammenhang mit, für oder in KI-Systemen, KI-Modellen oder Generativen Sprachmodellen.

Contents

Is a 'Librarian of the Web' really needed?
H. Unger 1

Centroid Terms as Text Representatives
M. M. Kubek and H. Unger 7

Spreading Activation: A Fast Calculation Method for Text Centroids
M. M. Kubek, T. Böhme and H. Unger 27

Empiric Experiments with Text-representing Centroids
M. M. Kubek, T. Böhme and H. Unger 39

Towards a Librarian of the Web
M. M. Kubek and Herwig Unger 55

A Concept Supporting a Resilient, Fault-tolerant and Decentralised Search
H. Unger and M. M. Kubek 79

An Associative Ring Memory to Support Decentralised Search
H. Unger and M. M. Kubek 91

The WebEngine – A Fully Integrated, Decentralised Web Search Engine
M. M. Kubek and H. Unger 107

On Evolving Text Centroids
H. Unger and M. M. Kubek 121

Addendum 131

Authors 140

https://doi.org/10.51202/9783186863102-I - Generiert durch IP 216.73.217.60, am 08.05.2026, 00:42:05. © Urheberrechtlich geschützter Inhalt. Ohne gesonderte Erlaubnis ist jede urheberrechtliche Nutzung untersagt, insbesondere die Nutzung des Inhalts im Zusammenhang mit, für oder in KI-Systemen, KI-Modellen oder Generativen Sprachmodellen.

https://doi.org/10.51202/9783186863102-I - Generiert durch IP 216.73.217.60, am 08.05.2026, 00:42:05. © Urheberrechtlich geschützter Inhalt. Ohne gesonderte
Erlaubnis ist jede urheberrechtliche Nutzung untersagt, insbesondere die Nutzung des Inhalts im Zusammenhang mit, für oder in KI-Systemen, KI-Modellen oder Generativen Sprachmodellen.