

Data Analytics @ Schwabmünchen

Ingo Hild, Dr. Bernd Eberhard, Dr. Jürgen Almanstötter, Martina Flörchinger


18/11/2021

-
- | | | |
|-----------|--|----------|
| 1. | Ingo Hild, Dr. Bernd Eberhard: Einführung <ul style="list-style-type: none">• Data Analytics @ Schwabmünchen• Wertstrom / ETL & Cloud | ~ 5 Min. |
|-----------|--|----------|
-
- | | | |
|-----------|--|-----------|
| 2. | Ingo Hild, Dr. Bernd Eberhard: Daten & Produktionsverfahren <ul style="list-style-type: none">• Entwicklung & Implementierung eines Backtrackingsystems entlang des Wolfram-Wertstroms | ~ 10 Min. |
|-----------|--|-----------|
-
- | | | |
|-----------|--|-----------|
| 3. | Dr. Jürgen Almanstötter: Algorithmen & Datenanalyse <ul style="list-style-type: none">• Technische Prozessanalyse mit Deep-Learning• Dynamic Time warping (DTW): Ein Algorithmus zur Prozessoptimierung | ~ 15 Min. |
|-----------|--|-----------|
-
- | | | |
|-----------|--|-----------|
| 4. | Martina Flörchinger: Scripting & Ad-hoc Analyse <ul style="list-style-type: none">• Ad-hoc Analyse• Tutorial: Data wrangling toolbox – von Big Data zu neuen Einsichten | ~ 15 Min. |
|-----------|--|-----------|
-
- | | | |
|-----------|--|----------|
| 5. | Ingo Hild, Dr. Bernd Eberhard: Wrap Up | ~ 5 Min. |
|-----------|--|----------|
-

- 1.** Ingo Hild, Dr. Bernd Eberhard: Einführung ~ 5 Min.
 - Data Analytics @ Schwabmünchen
 - Wertstrom / ETL & Cloud
- 2.** Ingo Hild, Dr. Bernd Eberhard: Daten & Produktionsverfahren ~ 10 Min.
 - Entwicklung & Implementierung eines Backtrackingsystems entlang des Wolfram-Wertstroms
- 3.** Dr. Jürgen Almanstötter: Algorithmen & Datenanalyse ~ 15 Min.
 - Technische Prozessanalyse mit Deep-Learning
 - Dynamic Time warping (DTW): Ein Algorithmus zur Prozessoptimierung
- 4.** Martina Flörchinger: Scripting & Ad-hoc Analyse ~ 15 Min.
 - Ad-hoc Analyse
 - Tutorial: Data wrangling toolbox – von Big Data zu neuen Einsichten
- 5.** Ingo Hild, Dr. Bernd Eberhard: Wrap Up ~ 5 Min.

Data Analytics @ Schwabmünchen


Wertstrom – vom APW zum Wolframdraht



vom APW zum Metallpulver




Pulverpressen und Sintern





Sinterstab



Walzen und Hämmern



Wolframstab



Drahtzug


Endprodukt



Wolframdraht

Data Analytics @ Schwabmünchen

Wertstrom und Infrastruktur der Daten






vom Wertstrom zu einer effizienten Datenlandschaft!

-
- | | | |
|-----------|--|-----------|
| 1. | Ingo Hild, Dr. Bernd Eberhard: Einführung <ul style="list-style-type: none">• Data Analytics @ Schwabmünchen• Wertstrom / ETL & Cloud | ~ 5 Min. |
| <hr/> | | |
| 2. | Ingo Hild, Dr. Bernd Eberhard: Daten & Produktionsverfahren <ul style="list-style-type: none">• Entwicklung & Implementierung eines Backtrackingsystems entlang des Wolfram-Wertstroms | ~ 10 Min. |
| <hr/> | | |
| 3. | Dr. Jürgen Almanstötter: Algorithmen & Datenanalyse <ul style="list-style-type: none">• Technische Prozessanalyse mit Deep-Learning• Dynamic Time warping (DTW): Ein Algorithmus zur Prozessoptimierung | ~ 15 Min. |
| <hr/> | | |
| 4. | Martina Flörchinger: Scripting & Ad-hoc Analyse <ul style="list-style-type: none">• Ad-hoc Analyse• Tutorial: Data wrangling toolbox – von Big Data zu neuen Einsichten | ~ 15 Min. |
| <hr/> | | |
| 5. | Ingo Hild, Dr. Bernd Eberhard: Wrap Up | ~ 5 Min. |
-

Produktionsprozess & -daten

Über den Materialfluss



Rückverfolgbarkeit ist notwendig für die Multiprozessanalyse – Aber leider nicht einfach in der W-Drahtherstellung!




Produktionsprozess & -daten

Der Draht bekommt einen Namen und zugehörigen Stammbaum



Produktionsprozess & -daten


Implementierung entlang der kompletten Prozesskette (~60 Prozessschritte, 34x Lesen und Schreiben)



Ein leistungsfähiges Traceability-System erfordert das vollständige Einbinden der Prozesskette!

Produktionsprozess & -daten

Unser IoT-Gateway: die „Spalt-CPU“






-
- | | | |
|-----------|--|----------|
| 1. | Ingo Hild, Dr. Bernd Eberhard: Einführung <ul style="list-style-type: none">• Data Analytics @ Schwabmünchen• Wertstrom / ETL & Cloud | ~ 5 Min. |
|-----------|--|----------|
-
- | | | |
|-----------|--|-----------|
| 2. | Ingo Hild, Dr. Bernd Eberhard: Daten & Produktionsverfahren <ul style="list-style-type: none">• Entwicklung & Implementierung eines Backtrackingsystems entlang des Wolfram-Wertstroms | ~ 10 Min. |
|-----------|--|-----------|
-
- | | | |
|-----------|--|-----------|
| 3. | Dr. Jürgen Almanstötter: Algorithmen & Datenanalyse <ul style="list-style-type: none">• Technische Prozessanalyse mit Deep-Learning• Dynamic Time warping (DTW): Ein Algorithmus zur Prozessoptimierung | ~ 15 Min. |
|-----------|--|-----------|
-
- | | | |
|-----------|--|-----------|
| 4. | Martina Flörchinger: Scripting & Ad-hoc Analyse <ul style="list-style-type: none">• Ad-hoc Analyse• Tutorial: Data wrangling toolbox – von Big Data zu neuen Einsichten | ~ 15 Min. |
|-----------|--|-----------|
-
- | | | |
|-----------|--|----------|
| 5. | Ingo Hild, Dr. Bernd Eberhard: Wrap Up | ~ 5 Min. |
|-----------|--|----------|
-

Technische Prozessanalyse mit Deep-Learning

Zielsetzung: Generierung von interpretierbaren technischen Zusammenhängen




Prozess



Datenrepräsentation



Deep Learning



Prozessverständnis




Technische Prozessanalyse mit Deep-Learning

Prozess: Sintern von Wolframstäben




Prozessprinzip




Stromstärke: mehrere kA
Temperatur: > 2800°C
Enddichte: 80-95 % der max. Dichte (19,3 g/cm³)


Vorgabe des Strom-Zeitverlaufs



Dotierung K, Si, Al




Sintern



K verbleibt in Bläschen



Technische Prozessanalyse mit Deep-Learning

Prozesswirkung auf das Material



Ausgangszustand

Verdichtung
durch Sintern




Endzustand


Zielgröße: Sinterdichte

Technische Prozessanalyse mit Deep-Learning


Datenrepräsentation: Datensätze von 1270 Wolframstäben



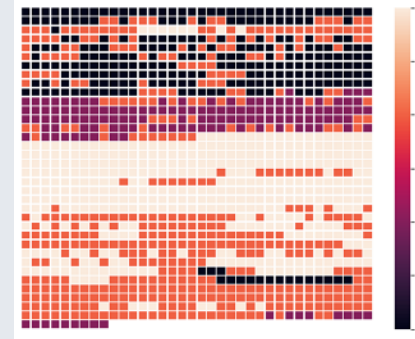
K [ppm]




Al [ppm]




Si [ppm]




Fe [ppm]




Korngröße [μm]



Schüttdichte [g/cm^3]





Klopfdichte [g/cm^3]



Leistung [kW]

Inputgrößen




Sinterdichte [g/cm^3]

Zielgröße

Technische Prozessanalyse mit Deep-Learning

Programmierung und Training des neuronalen Netzwerks



Technische Prozessanalyse mit Deep-Learning



Multidimensionaler Gradient



Zweck des trainierten Netzwerks ist **nicht** eine **Vorhersage** der Sinterdichte

Ziel: Ermittlung des **Gradienten** zur Darstellung der Variation der Zielgröße unter Änderung der Inputgrößen

Ergebnis: Quantitatives Maß für den Einfluss der einzelnen Prozeßparameter auf die Sinterdichte





Berechnung des lokalen Gradienten von $f(x_1, x_2, \dots)$ mittels trainiertem neuronalen Netzwerk

Technische Prozessanalyse mit Deep-Learning

Anwendungsfall: Erhöhung Sinterdichte



Produkt A



Prozessführung

Maßnahmen zur Erhöhung der Sinterdichte

1. Materialparameter


- Erhöhung Fe-Konzentration
- Erhöhung Korngröße (SSS)
- Erhöhung Al-Konzentration

2. Prozessführung

- Verbesserungspotential an 2. Rampe


Technische Prozessanalyse mit Deep-Learning

Einfluss der Prozessparameter auf die Sinterdichte



Materialparameter

Produkt B



Prozessführung

Maßnahmen zur Erhöhung der Sinterdichte

1. Materialeigenschaften

- Erhöhung Fe-Konzentration
- Erhöhung Korngroße (SSS)
- Erhöhung Al-Konzentration

2. Prozessführung

- Verbesserungspotential bei 1. Haltezeit und in Endstufe der 3. Haltezeit

Technische Prozessanalyse mit Deep-Learning

Zusammenfassung & Fazit



Die Analyse von Gradienten in einem trainierten neuronalen Netzwerk zeigt Schlüsselzusammenhänge, die durch traditionelle statistische Analysen nicht ohne weiteres identifiziert werden können

Die Gradientenanalyse automatisiert die Vorhersage der Richtungen im Parameterraum (Konzentration spezifischer Dop-Elemente oder Prozessparameter) zur Optimierung der Zielgröße (Sinterdichte)

Die vorgestellte Methode ist universell und kann auf eine Vielzahl von Problemen angewendet werden, von Produktionsprozessen bis zu F&E-Projekten

Technische Prozessanalyse mit Dynamic Time Warping

Zielsetzung: Prozessoptimierung



Prozess



Datenrepräsentation



Datentransformation



Prozessoptimierung




Technische Prozessanalyse mit Dynamic Time Warping



Prozess: Ziehen von Wolframdrähten




Grundprinzip des Drahtzugs



Mögliche Defekte: Oberflächenspalten



Detektion von Oberflächenspalten




Technische Prozessanalyse mit Dynamic Time Warping


Spaltsignal vor und nach Ziehprozess



Spaltsignal
vor dem
Ziehstein




Spaltsignal
nach dem
Ziehstein



Herausforderungen in der Datenanalyse

1. Signale haben unterschiedliche Gesamtlänge
2. Nichtlineare Streckung über die Drahtlänge
3. Entstehung neuer Risse und Änderung existierender Spalten
4. Sehr große Datensätze: Auflösung 1 cm bei bis zum mehreren 1000 m Gesamtdrahtlänge



Datensatz
linear gestreckt

Reale Messung
im Prozess

Technische Prozessanalyse mit Dynamic Time Warping

Verwandte Problemstellung: Spracherkennung




Eliminiere die nichtlinearen Zeitverschiebungen zwischen zwei Mustern

Word "Mothers"

Referenzperson A

Person B



IEEE TRANSACTIONS ON ACOUSTICS, SPEECH, AND SIGNAL PROCESSING, VOL. ASSP-26, NO. 1, FEBRUARY 1978 43

Dynamic Programming Algorithm Optimization for Spoken Word Recognition

HIROAKI SAKOE AND SEIBI CHIBA


Abstract—This paper reports on an optimum dynamic programming (DP) based time-normalization algorithm for spoken word recognition. First, a general principle of time-normalization is given using time-warping function. Then, two time-normalized distance definitions, called symmetric and asymmetric forms, are derived from the principle. These two forms are compared with each other through theoretical discussions and experimental studies. The symmetric form algorithm superiority is established. A new technique, called slope constraint, is successfully introduced, in which the warping function slope is restricted so as to improve discrimination between words in different categories. The effective slope constraint characteristic is qualitatively analyzed, and the optimum slope constraint condition is determined through experiments. The optimized algorithm is then extensively subjected to experimental comparison with various DP-algorithms, previously applied to spoken word recognition by different research groups. The experiment shows that the present algorithm gives no more than about two-thirds errors, even compared to the best conventional algorithm.

vestigations were made, based on the assumption that speech patterns are time-sampled with a common and uniform sampling period, as in most general cases. One of the problems discussed in this paper involves the relative superiority of either a symmetric form of DP-matching or an asymmetric one. In the asymmetric form, time-normalization is achieved by transforming the time axis of a speech pattern onto that of the other. In the symmetric form, on the other hand, both time axes are transformed onto a temporarily defined common axis. Theoretical and experimental comparisons show that the symmetric form gives better recognition than the asymmetric one. Another problem discussed concerns slope constraint technique. Since too much of the warping function flexibility sometimes results in poor discrimination between words in different categories, a constraint is newly introduced on the warping

Gegenseitige Abbildung

Suche den Pfad mit minimaler Distanz (i,j) um maximale Koinzidenz der Signale zu erreichen


$$d(C_n) = d(i, j) = ||a_i - b_j||$$




Technische Prozessanalyse mit Dynamic Time Warping

Anwendung: Optimierung des Ziehsteinwinkels hinsichtlich Spaltigkeit

Ziehsteinwinkel 16°



5 aufeinander-
folgende Stufen




→ Starke Zunahme der Anzahl von Spalten bereits in der zweite Ziehstufen



Technische Prozessanalyse mit Dynamic Time Warping

Anwendung: Optimierung des Ziehsteinwinkels hinsichtlich Spaltigkeit

Ziehsteinwinkel 14°



5 aufeinander-
folgende Stufen




→ Signifikanter Zunahme von Spalten erst in der letzten Ziehstufe

Technische Prozessanalyse mit Dynamic Time Warping


Anwendung: Optimierung des Ziehsteinwinkels hinsichtlich Spaltigkeit



Ziehsteinwinkel 12°



5 aufeinander-
folgende Stufen



→ Keine signifikante Zunahme von Spalten → Optimaler Ziehsteinwinkel

Technische Prozessanalyse mit Dynamic Time Warping (DTW)

Zusammenfassung & Fazit



Der DTW-Algorithmus dient allgemein der Erkennung von Ähnlichkeiten zwischen Signalen oder Zeitreihen




Die Anwendung des DTW-Algorithmus ermöglicht die Verfolgung der Änderung von Spaltsignalen mit hoher Auflösung entlang der Drahtlänge

Nutzen: Identifikation kritischer Prozessparameter (hier Ziehsteinwinkel) über die Wertschöpfungskette

-
- | | | |
|-----------|--|-----------|
| 1. | Ingo Hild, Dr. Bernd Eberhard: Einführung <ul style="list-style-type: none">• Data Analytics @ Schwabmünchen• Wertstrom / ETL & Cloud | ~ 5 Min. |
| <hr/> | | |
| 2. | Ingo Hild, Dr. Bernd Eberhard: Daten & Produktionsverfahren <ul style="list-style-type: none">• Entwicklung & Implementierung eines Backtrackingsystems entlang des Wolfram-Wertstroms | ~ 10 Min. |
| <hr/> | | |
| 3. | Dr. Jürgen Almanstötter: Algorithmen & Datenanalyse <ul style="list-style-type: none">• Technische Prozessanalyse mit Deep-Learning• Dynamic Time warping (DTW): Ein Algorithmus zur Prozessoptimierung | ~ 15 Min. |
| <hr/> | | |
| 4. | Martina Flörchinger: Scripting & Ad-hoc Analyse <ul style="list-style-type: none">• Ad-hoc Analyse• Tutorial: Data wrangling toolbox – von Big Data zu neuen Einsichten | ~ 15 Min. |
| <hr/> | | |
| 5. | Ingo Hild, Dr. Bernd Eberhard: Wrap Up | ~ 5 Min. |
-

Werkzeugkiste für Datenverarbeitung – Einsichten aus Big Data

Eine praxisnaher Herangehensweise um Einsichten aus Daten zu generieren



Werkzeugkiste für Datenverarbeitung – Einsichten aus Big Data

Wir starten mit „Big Data“ – Laut Definition sind das viele, unsortierte und schnell neu generierende Datensätze



Big Data



BIG DATA ANALYTICS PLATFORM - DATA LAKE

Vorauswahl: Tabellen auswählen,

Spalten Auswählen (select),

Reihen nach Konditionen filtern (filter)

Tabellen aggregieren (aggregate)


Tabellen zusammenfügen (join)



databricks


Werkzeugkiste für Datenverarbeitung – Einsichten aus Big Data

Wir starten mit „Big Data“ – Laut Definition sind das viele, unsortierte und schnell neu generierende Datensätze



Werkzeugkiste für Datenverarbeitung – Einsichten aus Big Data

Wir starten mit „Big Data“ – Laut Definition sind das viele, unsortierte und schnell neu generierende Datensätze



Werkzeugkiste für Datenverarbeitung – Einsichten aus Big Data

Beispiel



FRAGE:

Korreliert die Anzahl der Teilungen in der Drahtfertigung mit Fehlermerkmalen in der Warenausgangsprüfung?

HERAUSFORDERUNG:

Eine neue Datenquelle ist noch nicht im Datalake, sondern nur per Excel zugänglich.

Werkzeugkiste für Datenverarbeitung – Einsichten aus Big Data

Erste Schritte: Extraktion der benötigten Daten via Databricks



Stillstand_Reduced Python Schedule

KatherineJohnsonCluster File Edit View: Standard Permissions Run All Clear Comments Experiment Revision history

Cmd 7

```
1 # get parquet content Stillstand files
2
3 stageDf = (spark.read.parquet("/mnt/stage/SWM-Draht/EI/Stillstand")
4 )
```

(1) Spark Jobs

stageDf: pyspark.sql.dataframe.DataFrame = [DATUM: timestamp, MESSUNG: string ... 5 more fields]

Command took 11.51 seconds -- by adminaug.mf@osram.com at 16.11.2021, 10:36:04 on KatherineJohnsonCluster

Cmd 8

```
1 # for debugging
2 display(stageDf)
```

(1) Spark Jobs

	DATUM	MESSUNG	GRUND	BEREICH	MASCHNR	PRNR	DATUM.UTC
1	2020-08-26T06:02:39.000+0000	Beendet	Teilung	160006	null	1051585636	2020-08-26T04:02:39.000+0000
2	2021-01-21T09:09:28.000+0000	Beendet	Teilung	160006	115	1052467168	2021-01-21T08:09:28.000+0000
3	2020-02-25T10:21:33.000+0000	Beendet	Teilung	160006	115	1050581558	2020-02-25T09:21:33.000+0000
4	2021-03-09T12:16:59.000+0000	Beendet	Teilung	160006	38	1052848209	2021-03-09T11:16:59.000+0000
5	2020-02-25T22:56:48.000+0000	Beendet	Teilung	160006	115	1050587852	2020-02-25T21:56:48.000+0000
6	2020-07-13T08:04:46.000+0000	Beendet	Teilung	160010	224	1051483215	2020-07-13T06:04:46.000+0000
7							

Truncated results, showing first 1000 rows.

Command took 8.18 seconds -- by adminaug.mf@osram.com at 16.11.2021, 10:36:04 on KatherineJohnsonCluster

Werkzeugkiste für Datenverarbeitung – Einsichten aus Big Data

Filtern der benötigten Daten und Export der Daten



	DATUM ▲	MESSUNG ▲	GRUND ▼	BEREICH ▲	MASCHNR ▲	PRNR ▲	DATUM_UTC ▲
1	2020-08-26T06:02:39.000+0000	Beendet	Teilung	160006	null	1051585636	2020-08-26T04:02:39.000+0000
2	2021-01-21T09:09:28.000+0000	Beendet	Teilung	160006	115	1052467168	2021-01-21T08:09:28.000+0000
3	2020-02-25T10:21:33.000+0000	Beendet	Teilung	160006	115	1050581558	2020-02-25T09:21:33.000+0000
4	2021-03-09T12:16:59.000+0000	Beendet	Teilung	160006	38	1052848209	2021-03-09T11:16:59.000+0000
5	2020-02-25T22:56:48.000+0000	Beendet	Teilung	160006	115	1050587852	2020-02-25T21:56:48.000+0000
6	2020-07-13T08:04:46.000+0000	Beendet	Teilung	160010	224	1051483215	2020-07-13T06:04:46.000+0000
7	2020-12-01T22:47:05.000+0000	Beendet	Teilung	160006	115	1052215004	2020-12-01T21:47:05.000+0000

Truncated results, showing first 1000 rows.



Command took 8.18 seconds -- by adminaug.mf@osram.com at 16.11.2021, 10:36:04 on KatherineJohnsonCluster

Cmd 9

```
1 reducedDf = stageDf.filter(col("GRUND") == "Teilung").filter(col("DATUM_UTC") > '2020-01-01T00:00:00.000+0000')
```

▸ reducedDf: pyspark.sql.dataframe.DataFrame = [DATUM: timestamp, MESSUNG: string ... 5 more fields]


Command took 0.19 seconds -- by adminaug.mf@osram.com at 16.11.2021, 10:36:04 on KatherineJohnsonCluster

Cmd 10

```
1 # save as CSV
2 CsvExport(reducedDf, "/mnt/reduced/SWM-Draht/EI/Stillstand.csv")
```


Werkzeugkiste für Datenverarbeitung – Einsichten aus Big Data

Nächster Schritt: Verarbeiten der Daten in R



Werkzeugkiste für Datenverarbeitung – Einsichten aus Big Data


Nächster Schritt: Verarbeiten der Daten in R



-
- | | | |
|-----------|--|-----------|
| 1. | Ingo Hild, Dr. Bernd Eberhard: Einführung <ul style="list-style-type: none">• Data Analytics @ Schwabmünchen• Wertstrom / ETL & Cloud | ~ 5 Min. |
| <hr/> | | |
| 2. | Ingo Hild, Dr. Bernd Eberhard: Daten & Produktionsverfahren <ul style="list-style-type: none">• Entwicklung & Implementierung eines Backtrackingsystems entlang des Wolfram-Wertstroms | ~ 10 Min. |
| <hr/> | | |
| 3. | Dr. Jürgen Almanstötter: Algorithmen & Datenanalyse <ul style="list-style-type: none">• Technische Prozessanalyse mit Deep-Learning• Dynamic Time warping (DTW): Ein Algorithmus zur Prozessoptimierung | ~ 15 Min. |
| <hr/> | | |
| 4. | Martina Flörchinger: Scripting & Ad-hoc Analyse <ul style="list-style-type: none">• Ad-hoc Analyse• Tutorial: Data wrangling toolbox – von Big Data zu neuen Einsichten | ~ 15 Min. |
| <hr/> | | |
| 5. | Ingo Hild, Dr. Bernd Eberhard: Wrap Up | ~ 5 Min. |
-

Erkenntnis #1

Data Analytics ist ein fortlaufender Prozess



Ergebnis:

keine Nuggets



viele Flocken




daher:

schnelles und häufiges Durchlaufen
des Cycles notwendig

Schnelles und häufiges Durchlaufen des Crisp Cycles für erfolgreiche Anwendung der Data Analytics notwendig


Erkenntnis #2

Zusammenarbeit zwischen Fachexperten und Data-Analysten erforderlich



Prozessing.


Data Analyst



Data Analysten und Prozessingenieure müssen eng zusammenarbeiten → Einer allein kommt nicht zum Ziel

Holistic Traceability @ AM

Vom Pulver bis zur fertigen Lampe



Potenzial zur Verbesserung der gesamten Wertschöpfungskette über mehrere Werke



Q&A

