




Extracting recipe  
ingredients  
from cookbooks

Irrlichter  
von  
Torsten Knauf

Der Beginn einer  
Master-Arbeit



- 1 Tag-Schema
  - Schema.org/Recipe
  - cueML
- 2 Algorithmen um Informationen zu extrahieren
  - RE
  - CRF
  - Dictionary-based
- 3 Schwerpunkt setzen

# Tag-Schema

---

```
Mom's World Famous Banana Bread
By John Smith, May 8, 2009

This classic banana bread recipe comes from my mom -- the
walnuts add a nice texture and flavor to the banana bread.
Prep Time: 15 minutes
Cook time: 1 hour
Yield: 1 loaf
Tags: Low fat
Nutrition facts:
240 calories, 9 grams fat
Ingredients:
- 3 or 4 ripe bananas, smashed
- 1 egg
- 3/4 cup of sugar
...
Instructions:
Preheat the oven to 350 degrees. Mix in the ingredients in
a bowl. Add the flour last. Pour the mixture into a loaf
pan and bake for one hour.
140 comments:
From Janel, May 5 -- thank you, great recipe!
...
```

(Schema.org 2016)

```

<div itemscope itemtype="http://schema.org/Recipe">
  <span itemprop="name">Mom's World Famous Banana Bread</span>
  By <span itemprop="author">John Smith</span>,
  <meta itemprop="datePublished" content="2009-05-08">May 8, 2009
  
  <span itemprop="description">This classic banana bread recipe comes
  from my mom -- the walnuts add a nice texture and flavor to the banana
  bread.</span>
  Prep Time: <meta itemprop="prepTime" content="PT15M">15 minutes
  Cook time: <meta itemprop="cookTime" content="PT1H">1 hour
  Yield: <span itemprop="recipeYield">1 loaf</span>
  Tags: <link itemprop="suitableForDiet" href="http://schema.org/LowFatDiet" />Low fat
  <div itemprop="nutrition"
    itemscope itemtype="http://schema.org/NutritionInformation">
    Nutrition facts:
    <span itemprop="calories">240 calories</span>,
    <span itemprop="fatContent">9 grams fat</span>
  </div>
  Ingredients:
  - <span itemprop="recipeIngredient">3 or 4 ripe bananas, smashed</span>
  - <span itemprop="recipeIngredient">1 egg</span>
  - <span itemprop="recipeIngredient">3/4 cup of sugar</span>
  ...
  Instructions:
  <span itemprop="recipeInstructions">
  Preheat the oven to 350 degrees. Mix in the ingredients in a bowl. Add
  the flour last. Pour the mixture into a loaf pan and bake for one hour.
  </span>
  140 comments:
  <div itemprop="interactionStatistic" itemscope itemtype="http://schema.org/InteractionCounter">
    <meta itemprop="interactionType" content="http://schema.org/CommentAction" />
    <meta itemprop="userInteractionCount" content="140" />
  </div>
  From Janel, May 5 -- thank you, great recipe!
  ...
</div>

```

## Pfannekuchen (Rezept mit Bild) von 06onkel | Chefkoch.de



[www.chefkoch.de](http://www.chefkoch.de) › [Rezepte](#) › [Kategorien](#) › [Menüart](#) › [Frühstück](#) ▼

★★★★★ Bewertung: 4,3 - 93 Rezensionen - 30 Min.

20.07.2005 - **Pfannekuchen**, ein gutes Rezept mit Bild aus der Kategorie Frühstück. 93 Bewertungen: Ø 4,3. Tags: Braten, Camping, einfach, Frühstück, ...

## Pfannekuchen Rezepte - kochbar.de

[www.kochbar.de](http://www.kochbar.de) › [Rezepte](#) ▼

Die besten Pfannekuchen Rezepte - Pfannekuchen Rezepte und viele weitere beliebte Kochrezepte finden Sie bei kochbar.de.

## Pfannekuchen Muttis Rezept :) - Rezept mit Bild - kochbar.de



[www.kochbar.de](http://www.kochbar.de) › [Rezept](#) ▼

★★★★★ Bewertung: 4,8 - 16 Abstimmungsergebnisse - 30 Min. - Kalorien: 171

03.10.2008 - Das perfekte **Pfannekuchen Muttis Rezept :)**-Rezept mit Bild und einfacher Schritt-für-Schritt-Anleitung: Butter, Vanille Zucker und Zucker ...

```

<script type="application/ld+json">
{
  "@context": "http://schema.org",
  "@type": "Recipe",
  "datePublished": "2005-07-20",
  "description": "Pfannekuchen, ein gutes Rezept mit Bild aus der Kategorie Fr&uuml;hst&uuml;ck",
  "image": "http://static.chefkoch-cdn.de/ck.de/rezepte/36/36386/875411-960x720-pfannekuchen.jpg",
  "recipeIngredient": [
    "250 g Mehl ",
    "4 Ei(er) ",
    " Salz
  ],
  "name": "Pfannekuchen",
  "prepTime": "PT30M",
  "recipeInstructions": "Den ganzen Teig mit dem Mixer zubereiten (Achtung es spritzt), so dass es ei
Eine Pfanne mit etwas Öl heiß werden lassen und dann eine Suppenkelle Teig in die Pfanne geben, dabei
Dazu passen süße sowie auch herzhaftere Sachen, z. B. Nutella, Leberwurst, Konfitüren, Lachs usw.",
  "recipeYield": "4"
,
  "aggregateRating": {
    "@type": "AggregateRating",
    "ratingValue": "4.27",
    "reviewCount": "93",
    "worstRating": 0,
    "bestRating": 5
  }
}
</script>
<script type="text/javascript">
var _simplora_params = { recipes: [] };
_simplora_params.recipes.push({
  id: '363861121870267',
  name: 'Pfannekuchen',
  servings: 4,
  ingredients: [
    { id: '71', base_amount: '62.5', amount_unit: 'g', name: 'Mehl'},
    { id: '36', base_amount: '1', amount_unit: '', name: 'Ei(er)'},
    { id: '6', base_amount: '0', amount_unit: '', name: 'Salz'},
  ]
});

```

**Ingredients:**

- `<span itemprop="recipeIngredient" quantity="3-4" name="banana">3 or 4 ripe bananas, smashed</span>`
- `<span itemprop="recipeIngredient" quantity="1" name="egg">1 egg</span>`
- `<span itemprop="recipeIngredient" quantity="3/4" unit="cup" name="sugar">3/4 cup of sugar</span>`
- ...

**Instructions:**

```

<recipe type="Suppen." rcp-id="B-16">
  <head>Mock Turtle Suppe.</head>

  <p>Es wird hierzu für 24-30 Personen eine kräftige Bouillon von 8-10 Pfund Rindfleisch mit Wurzelwerk gekocht. Zugleich bringt man einen großen Kalbskopf, eine Schweineschnauze und Ohren, einen OchsenGaumen und eine geräucherte Ochsenzunge zu Feuer und kocht dies Alles gahr, aber nicht zu weich. Kalt, schneidet man es in kleine, länglich viereckige Stückchen, gibt das Fleisch in die Bouillon, nebst braunem Gewürz, ein Paar Messerspitzen Cayenne-Pfeffer, einige Kalbsmidder in Stückchen geschnitten (siehe Vorbereitungsregeln), kleine Saucissen, so viel Kalbskopfbühe, daß man hinreichend Suppe hat, und macht dies mit in Butter braun gemachtem Mehl gebunden. Nachdem dies Alles 1/4 Stunde gekocht hat, kommen noch Klöße von Kalbfleisch, einige hart gekochte Eier in Würfel geschnitten, ein Paar Eßlöffel Engl. Soja hinzu, und wenn die Klößchen einige Minuten gekocht haben, 1/2 Flasche Madeira und auch Austern, wenn man sie haben kann. Dann wird die Suppe sogleich angerichtet.</p>

  <note>Anmerk. Der Soja macht die Suppe gewürzreicher, kann jedoch gut wegbleiben, und statt Madeira kann man weißen Franzwein und etwas Rum nehmen. Sowohl die Bouillon als Kalbskopf können schon am vorhergehenden Tage, ohne Nachtheil der Suppe, gekocht werden. </note>
</cue:recipe>

```

Listing 1: Beispiel Rezept von Frau Davidis



```

<div itemscope itemtype="http://schema.org/Recipe http://cueML.org">
  <recipe type="Suppen." rcp-id="B-16">
    <head><span itemprop="name">Mock Turtle Suppe</span></head>

    <meta>
      <span itemprop="recipeYield" quantity="24-30" unit="Personen">24-30
        Personen</span>
      <span itemprop="recipeIngredient" name="Bouillon" reference="#Bouillon">
        Bouillon</span>
      <span itemprop="recipeIngredient" name="Rindfleisch" quantity="8-10" unit=
        "Pfund">8-10 Pfund Rindfleisch</span>
      <span itemprop="recipeIngredient">Wurzelwerk</span>
      <span itemprop="recipeIngredient" name="Cayennepfeffer" quantity="vague"
        unit="Messersptize">ein Paar Messerspitzen Cayenne-Pfeffer</span>
      <span itemprop="recipeIngredient" name="Ei" quantity="vague">einige hart
        gekochte Eier</span>
      ...
      <span itemprop="recipeIngredient" name="Auster" isOptional="True">Austern,
        wenn man sie haben kann</span>
      <span itemprop="recipeIngredient" quantity="vague" unit="EL" isOptional="
        True">ein Paar Eßlöffel Engl. Soja</span>
    <recipeIngredientAlternations>
      <alt>
        <span itemprop="recipeIngredient" name="Madeira" quantity="0.5" unit="
          Flasche">Madeira</span>
      </alt>
      <alt>
        <span itemprop="recipeIngredient" name="weißen_Franzwein">weißen
          Franzwein</span>
        <span itemprop="recipeIngredient" name="Rum" quantity="vague">etwas
          Rum</span>
      </alt>
    </recipeIngredientAlternations>
  </meta>

```

```

<div itemscope itemtype="http://cueML.schema.org/Recipe">
  <recipe type="Suppen." rcp-id="B-16">
    <meta>
      <span itemprop="name" content="Mock_Turtle_Suppe"/>

      <span itemprop="recipeYield" quantity="24-30" unit="Personen"/>

      <span itemprop="recipeIngredient" name="Bouillon" reference="#Bouillon"/>
      <span itemprop="recipeIngredient" name="Rindfleisch" quantity="8-10" unit="
        Pfund"/>
      <span itemprop="recipeIngredient" uncertainName="Wurzelwerk"/>
      <span itemprop="recipeIngredient" name="Cayennepfeffer" quantity="vague"
        unit="Messersptize"/>
      <span itemprop="recipeIngredient" name="Ei" quantity="vague"/>
      ...
      <span itemprop="recipeIngredient" name="Auster" isOptional="True"/>
      <span itemprop="recipeIngredient" uncertainName="Engl._Soja" quantity="
        vague" unit="EL" isOptional="True"/>
    <recipeIngredientAlternations>
      <alt>
        <span itemprop="recipeIngredient" name="Madeira" quantity="0.5" unit="
          Flasche"/>
      </alt>
      <alt>
        <span itemprop="recipeIngredient" name="weißen_Franzwein"/>
        <span itemprop="recipeIngredient" name="Rum" quantity="vague"/>
      </alt>
    </recipeIngredientAlternations>
  </meta>

  <span itemprop="recipeInstructions">...</span>
</recipe>
</div>

```

- Das Tag-Schema ist nicht trivial, da 3 unterschiedliche Themenbereiche:
  - TEI
  - Schema.org/Recipe
  - Information Extraction

## SoP (Separation of Concerns)

# Algorithmen um Informationen zu extrahieren

(*Skip The Pizza* 2012)

```
* Makes 6 to 8 servings

== Ingredients ==
* 2 tbsp extra virgin [[olive oil]]
* 3 cloves [[garlic]], finely chopped
[...]

== Directions ==
Heat olive oil and garlic in large skillet over
  low heat until
garlic begins to sizzle.
Add tomatoes, [...]

[[Category:Garlic Recipes]]
[...]
```

## Linear-chain Conditional Random Field

(Sutton and McCallum 2012), (The New York Times 2015)

Q=Quantity, U=Unit, I=Ingredient, P=Punctuation, OPT=Optional,  
 N=Negation, O=Other

2 EL Zucker	Q U I
Einen Schuss Zucker	Q U I
Zucker, wenn nicht süß genug	I P OPT N O O

Listing 4: training data

- Model  $p(X, Y) = \prod_{t=1}^T p(y_t|y_{t-1}) * p(x_t|y_t)$
- Trainings data + Magie mit Model



2 TL Zucker	Q U I
-------------	-------

Listing 5: Labeling

**Model**  $p(X, Y) = \prod_{t=1}^T p(y_t|y_{t-1}) * p(x_t|y_t)$

$$p(X, Y) = \frac{1}{Z(X, Y)} \prod_{t=1}^T \exp\left(\sum_{i,j \in S} \Theta_{i,j} * 1_{y_t=i} * 1_{y_{t-1}=j} + \sum_{i \in S} \sum_{j \in O} \mu_{o,i} * 1_{y_t=i} * 1_{x_t=o}\right)$$

$$Z(X, Y) = \sum_X \sum_Y \prod_{t=1}^T \exp(\sum_{i,j \in S} \Theta_{i,j} * 1_{y_t=i} * 1_{y_{t-1}=j} + \sum_{i \in S} \sum_{j \in O} \mu_{o,i} * 1_{y_t=i} * 1_{x_t=o}),$$

*S = all possible labels, O = all possible words*

$$p(X, Y) = \frac{1}{Z(X, Y)} \prod_{t=1}^T \exp\left(\sum_{k=1}^K \Theta_k * f_k(y_t, y_{t-1}, x_t)\right)$$

Bemerkung: Bestimmung der  $\Theta_k$  mathematisches Optimierungsproblem mit sehr wahrscheinlich keiner exakten Lösung

$$p(Y|X) = \frac{p(X,Y)}{\sum_{Y' \in S} p(Y',X)}$$

$$\text{prediction}(X) = \text{argmax}_Y (P(Y|X))$$

- Alles bis jetzt ist Hidden Markov Model
- Linear-chain CRF

- Teilmenge der  $f_k$
- Zusätzliche custom feature functions:

$$f_{k+1}(y_t, y_{t-1}, X) = 1_{x_t} \text{ startswith upper case}$$

$$f_{k+2}(y_t, y_{t-1}, X) = 1_{x_t} \text{ is in a domain specific dictionary}$$

$$f_{k+3}(y_t, y_{t-1}, X) = 1_{x_t} \text{ is in a domain specific dictionary} * \\ 1_{x_{t-1}} \text{ is an article}$$

- Aufwand einer Auswertung von *prediction*:  $(\#S)^2 * \#X$

## Implementierung der New York Times

3/4	I1	L12	NoCAP	NoPAREN	B-QTY
pound	I2	L12	NoCAP	NoPAREN	OTHER
shiitake	I3	L12	NoCAP	NoPAREN	B-NAME
mushrooms	I4	L12	NoCAP	NoPAREN	I-NAME
,	I5	L12	NoCAP	NoPAREN	OTHER
stemmed	I6	L12	NoCAP	NoPAREN	B-COMMENT
and	I7	L12	NoCAP	NoPAREN	I-COMMENT
quartered	I8	L12	NoCAP	NoPAREN	I-COMMENT

Listing 6: Extract of the training data for New York Times CRF

```
U01:%x[-1,0] U02:%x[0,0] U03:%x[1,0] U07:%x
    [0,3] U14:%x[0,1]/%x[0,2]
B
```

Listing 7: Feature templates



- Über 130.000 labelled ingredient phrases
- 89% sentence-level accuracy
- Getestet mit 481 ingredient phrases
  - Nicht eindeutig:  
*1 garlic clove, minced (optional)*
  - Mehrere Zutaten in einer ingredient phrase nicht vorgesehen:  
*4 tablespoons melted non-hydrogenated, melted coconut oil or canola oil*
  - Fehler vom Algorithmus oder vom Menschen?

## Ingredient Action relationship

(Ahmed 2009)


- 1 Dictionary-based entity recognition
  - Morphologisch Analyse der Wörter (z.B. Eier → Ei)
  - *Wort*  $\in$  *Domain specify dictionary*?
- 2 Welche entities gehören zusammen?
  - Rule based: POS + context free grammar
  - Dependency based

	Precision	Recall
• Rule based	97.39%	51.54%
• Dependency Based	95.4%	64.12%

# Schwerpunkt setzen





- Schema.org/Recipe erweitern
  - Via GitHub
  - Offensichtlich Bedarf (Chefkoch, NYT)
- Algorithmus
  - Keine 130.000 Trainingsdaten vs. bessere feature functions (domain-specific dictionary check)
  - Feature engineering + Label trainings data
  - Decision tree (*if negationWord*  $\in X$ ...)
- Webseite
  
- Ende Februar / im März nur noch schreiben

- SoP (Separation of Concerns)
- Martin Fowler:  
Duplizierter Code ist die Nummer eins der Gestanksparade
- Agile manifest: Simplicity –the art of maximizing the amount of work not done– is essential
- Praktiken von XP: Simple Design, consider the simplest thing that could possible work & YAGNI (You aren't gonna need it)



Danke für die  
Aufmerksamkeit

# Literaturverzeichnis I

-  Ahmed, Zeeshan (2009). "Domain Specific Information Extraction for Semantic Annotation". Diploma thesis. Charles University in Prague, Czech Republic and University of Nancy 2 in Nancy, France.
-  Schema.org (2016). *Schema.org*. URL: <https://schema.org/> (visited on 10/30/2016).
-  *Skip The Pizza* (2012). URL: <http://skipthepizza.com/blog/analyzing-the-ingredients-of-29200-recipes> (visited on 10/28/2016).
-  Sutton, Charles and Andrew McCallum (2012). "An Introduction to Conditional Random Fields". In: *Found. Trends Mach. Learn.* 4.4, pp. 267–373. ISSN: 1935-8237. DOI: 10.1561/2200000013. URL: <http://dx.doi.org/10.1561/2200000013>.

# Literaturverzeichnis II



The New York Times (2015). *Extracting Structured Data From Recipes Using Conditional Random Fields*. URL:  
[http://open.blogs.nytimes.com/2015/04/09/extracting-structured-data-from-recipes-using-conditional-random-fields/?\\_r=1](http://open.blogs.nytimes.com/2015/04/09/extracting-structured-data-from-recipes-using-conditional-random-fields/?_r=1) (visited on 10/30/2016).