

Cours 1

Introduction

A. Belaïd – LORIA - Nancy

Objectif du cours

- Vous aider à comprendre
 - Pourquoi on a besoin de reconnaître l'écriture ?
 - Comment doit-on procéder pour la décoder ?
 - Quelles précautions doit-on prendre pour bien reconnaître ?
 - Pourquoi ce n'est pas toujours facile de le faire ?
 - Quel résultat doit-on attendre ?
 - Les sources à utiliser ?
- Discuter les quelques problèmes que l'on rencontre quand on traite ce genre de données

Reconnaissance de l'écriture

- Deux supports

- Ecriture manuelle

- Reconnaissance du script

- Tri postal, reconnaissance automatique de montants de chèques
 - Identification/vérification de la signature (forensics)
 - Identification/vérification du scripteur

- Document

- Reconnaissance de la forme et du contenu

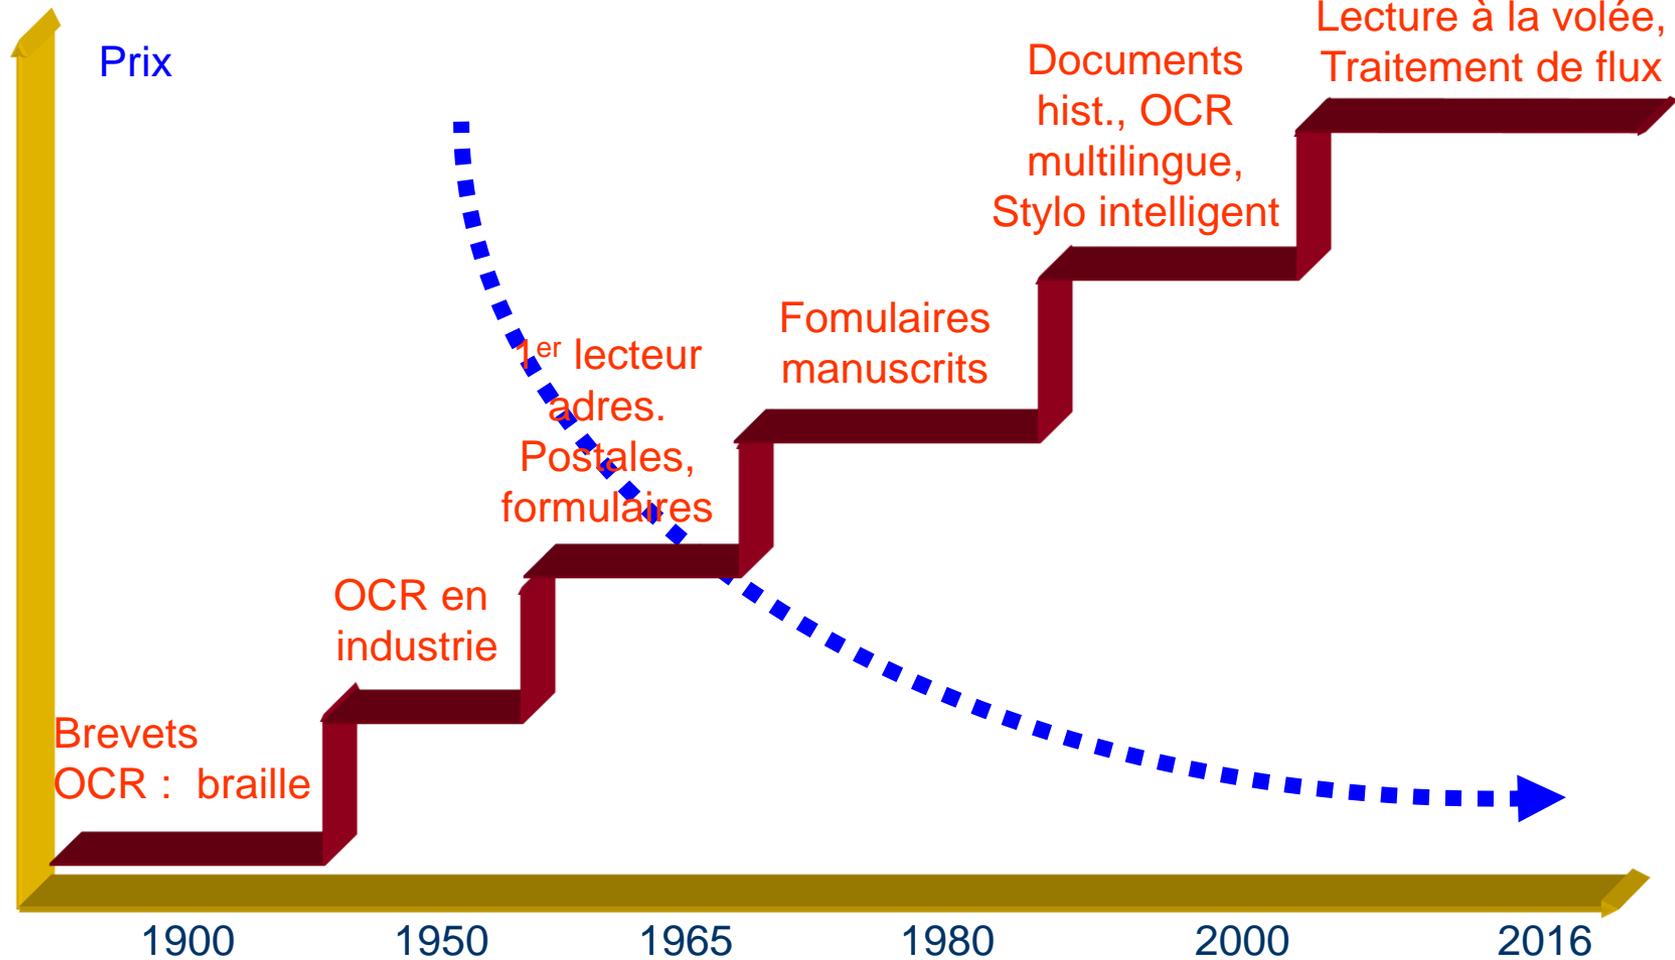
- Indexation de flux de documents entrants : courriers, faxes, commandes...
 - Archivage, datation de documents historiques
 - Analyse de plans cadastraux, schémas mécaniques, formulaires, etc.

- Applications différentes, mais

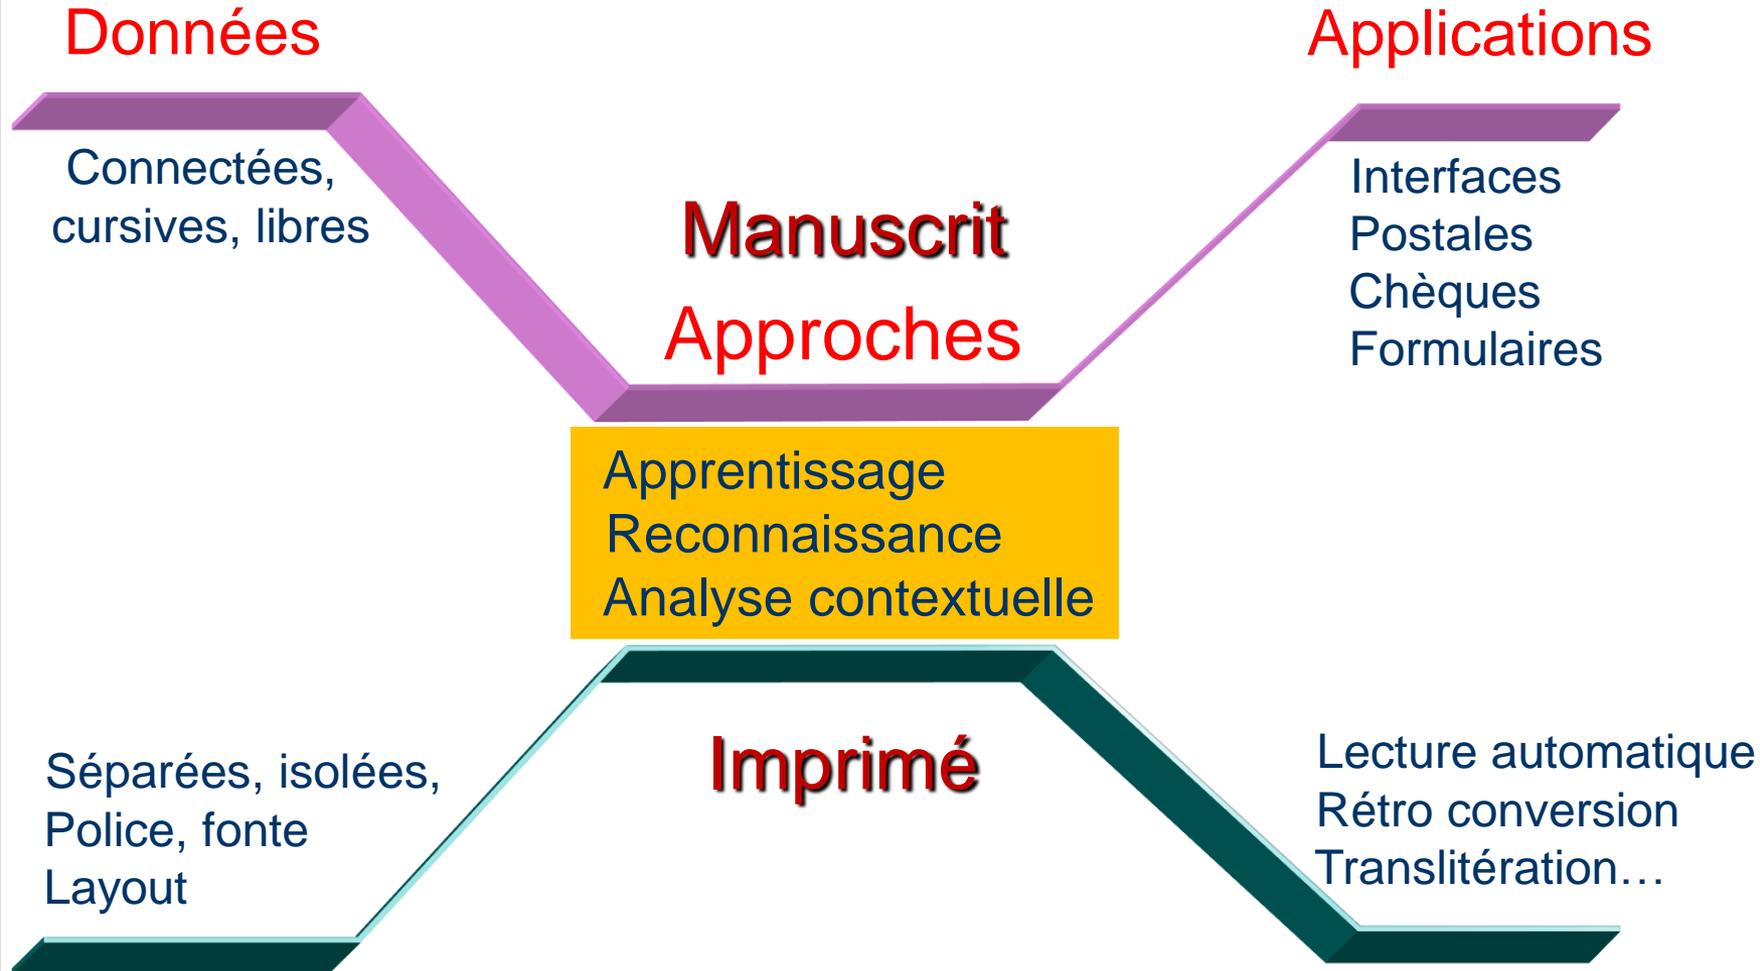
- méthodes et difficultés communes : connaissances métier

Historique : un siècle d'évolution

Maturité



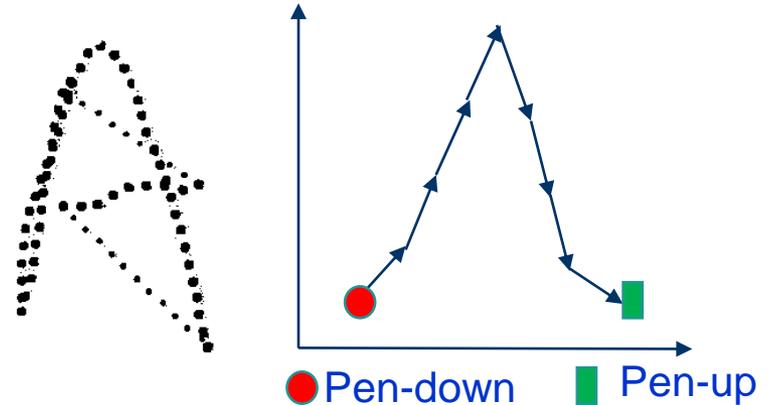
Manuscrit vs Imprimé



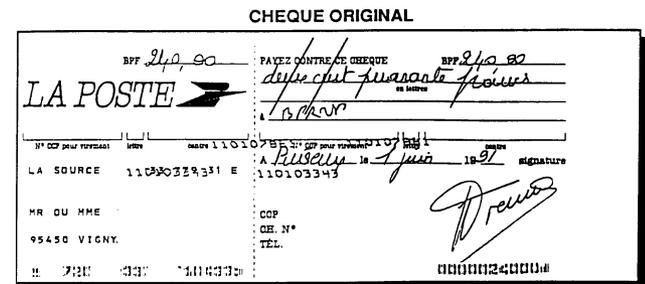
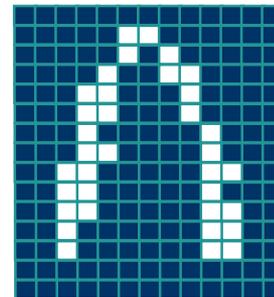
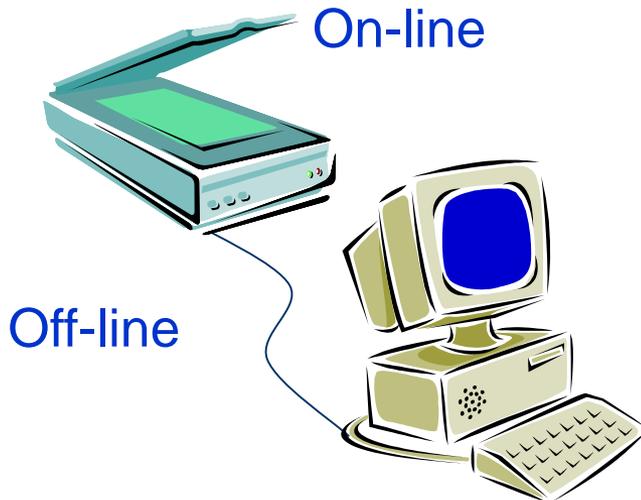
Manuscrit

- Différents facteurs

Mode d'acquisition



Applications stylo
Interfaces, mobiles, PDA



Courier, Chèques,
Formulaires

Manuscrit

- D'autres facteurs

Disposition spatiale des caractères

BOXED DISCRETE CHAR

Spaced Discrete Characters

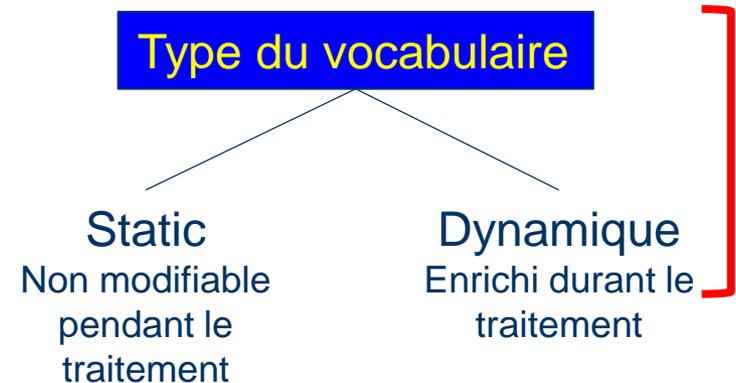
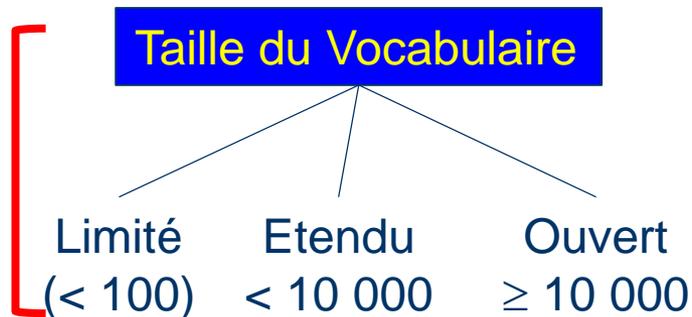
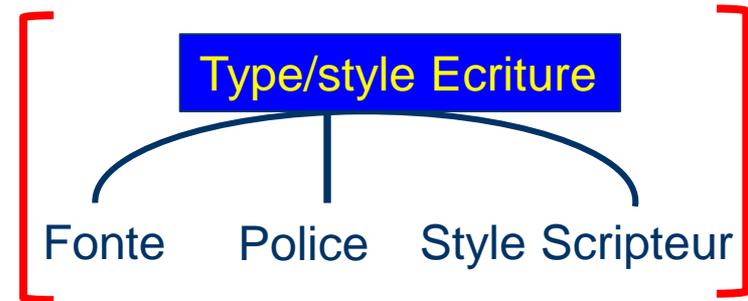
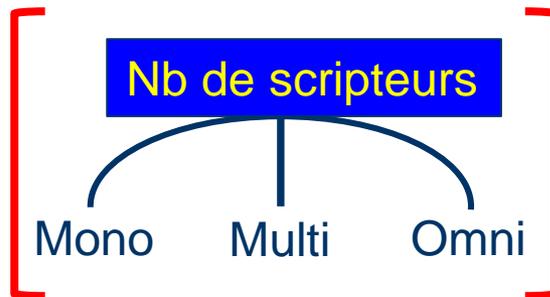
Run-on discretely written characters

pure cursive script writing

Mixed Cursive and Discrete

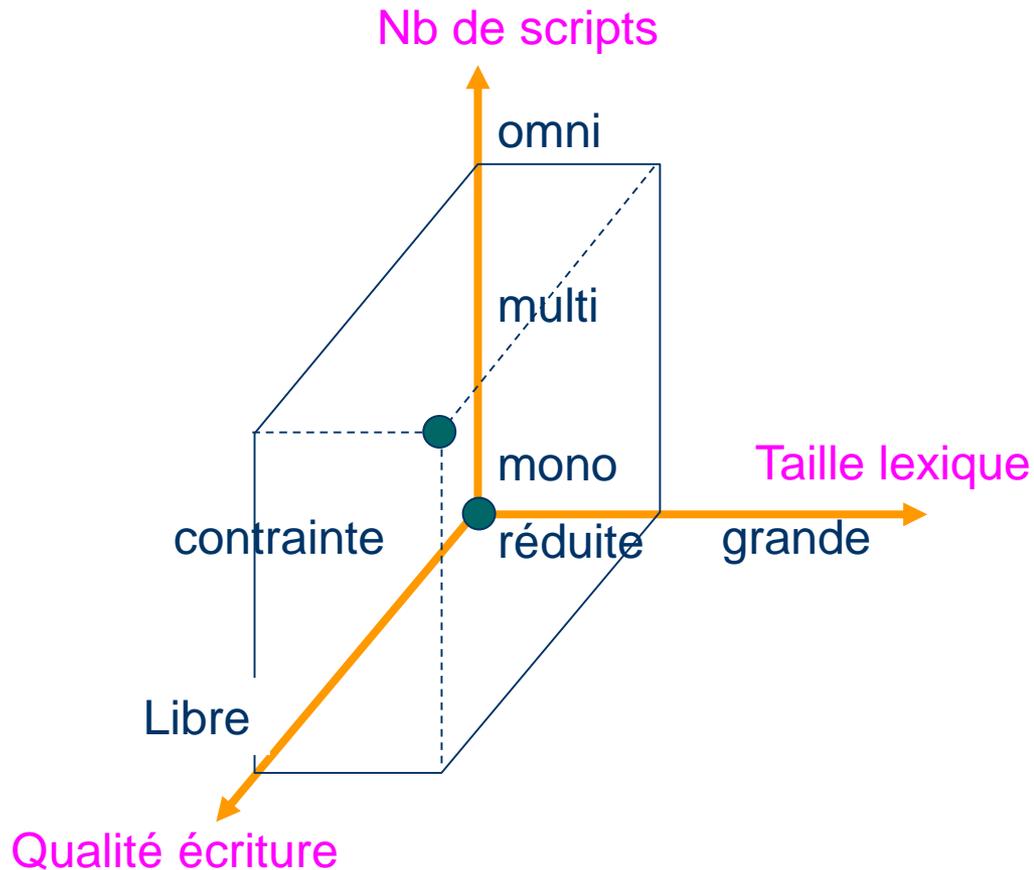
Manuscrit

- D'autres facteurs



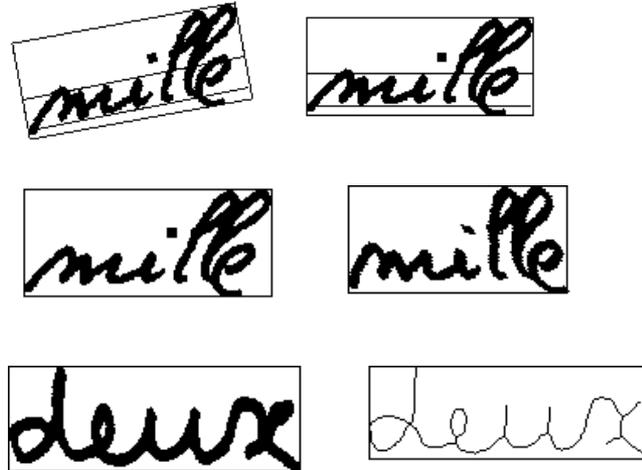
Introduction

Performances : critères influençant la qualité



Manuscrit : méthodes

Capture &
Prétraitement



Extraction de
caractéristiques

Haut niveau: boucles, hampes, jambages, etc.
Bas niveau: densité, contours, pixels

Représentation
& classification

Structurelle (primitives)
Statistique / stochastique

Post-traitement

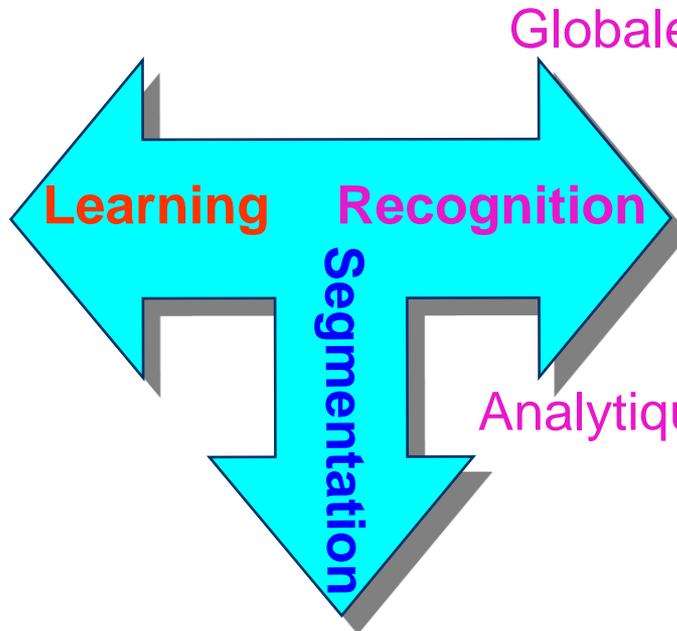
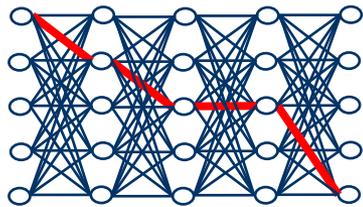
Contraintes lexicales, règles syntaxiques, langage

Manuscrit : méthodes

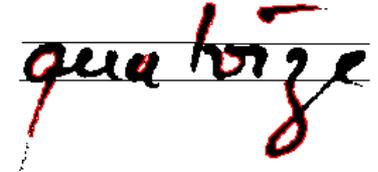
Modèle discriminant



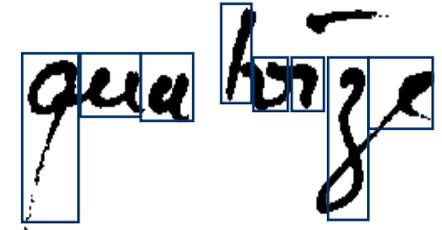
Chemin discriminant



Globale



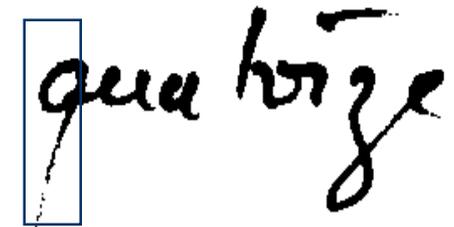
Analytique



Pré-segmentation

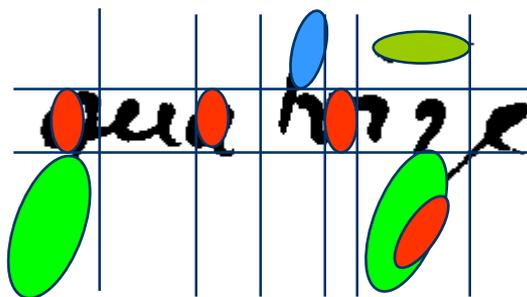
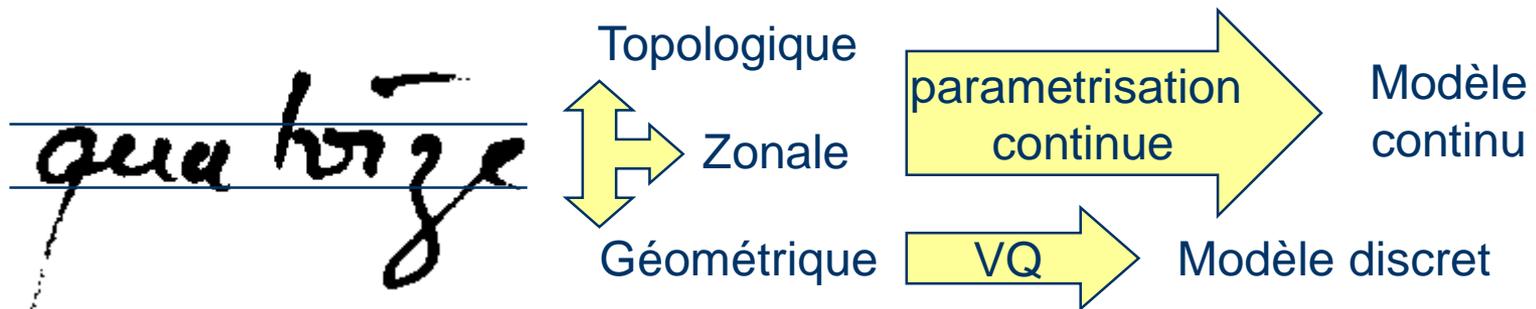


Interne



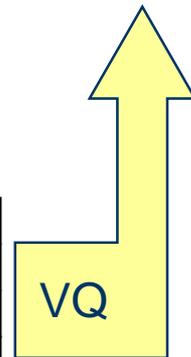
Fenêtre glissante

Manuscrit : codage

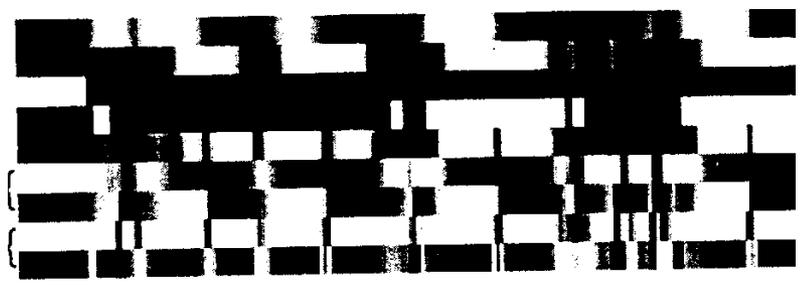
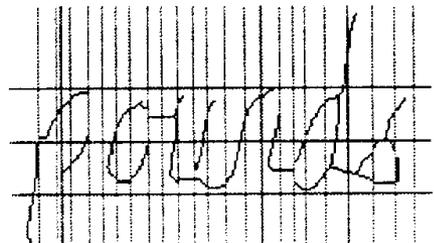
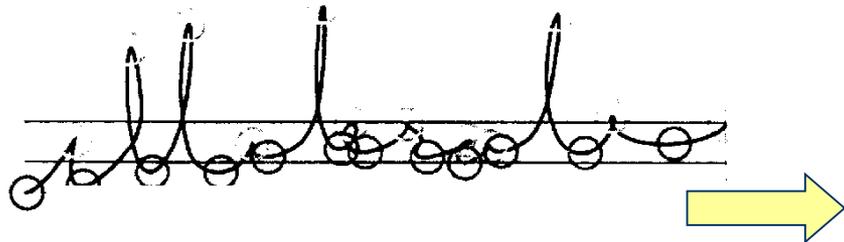
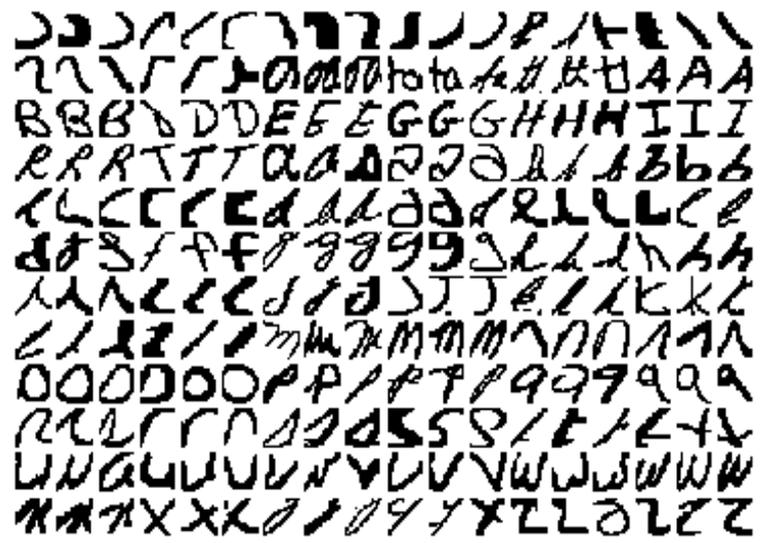
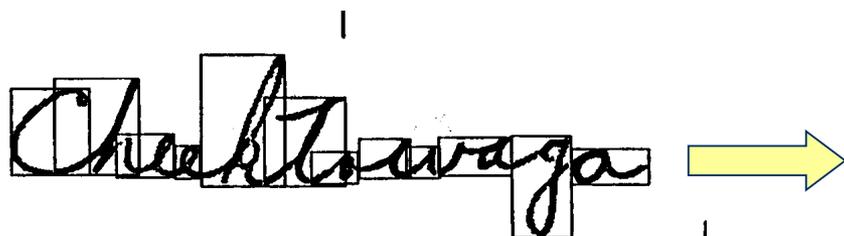


Hampe
Jambage
Barre T
Boucle

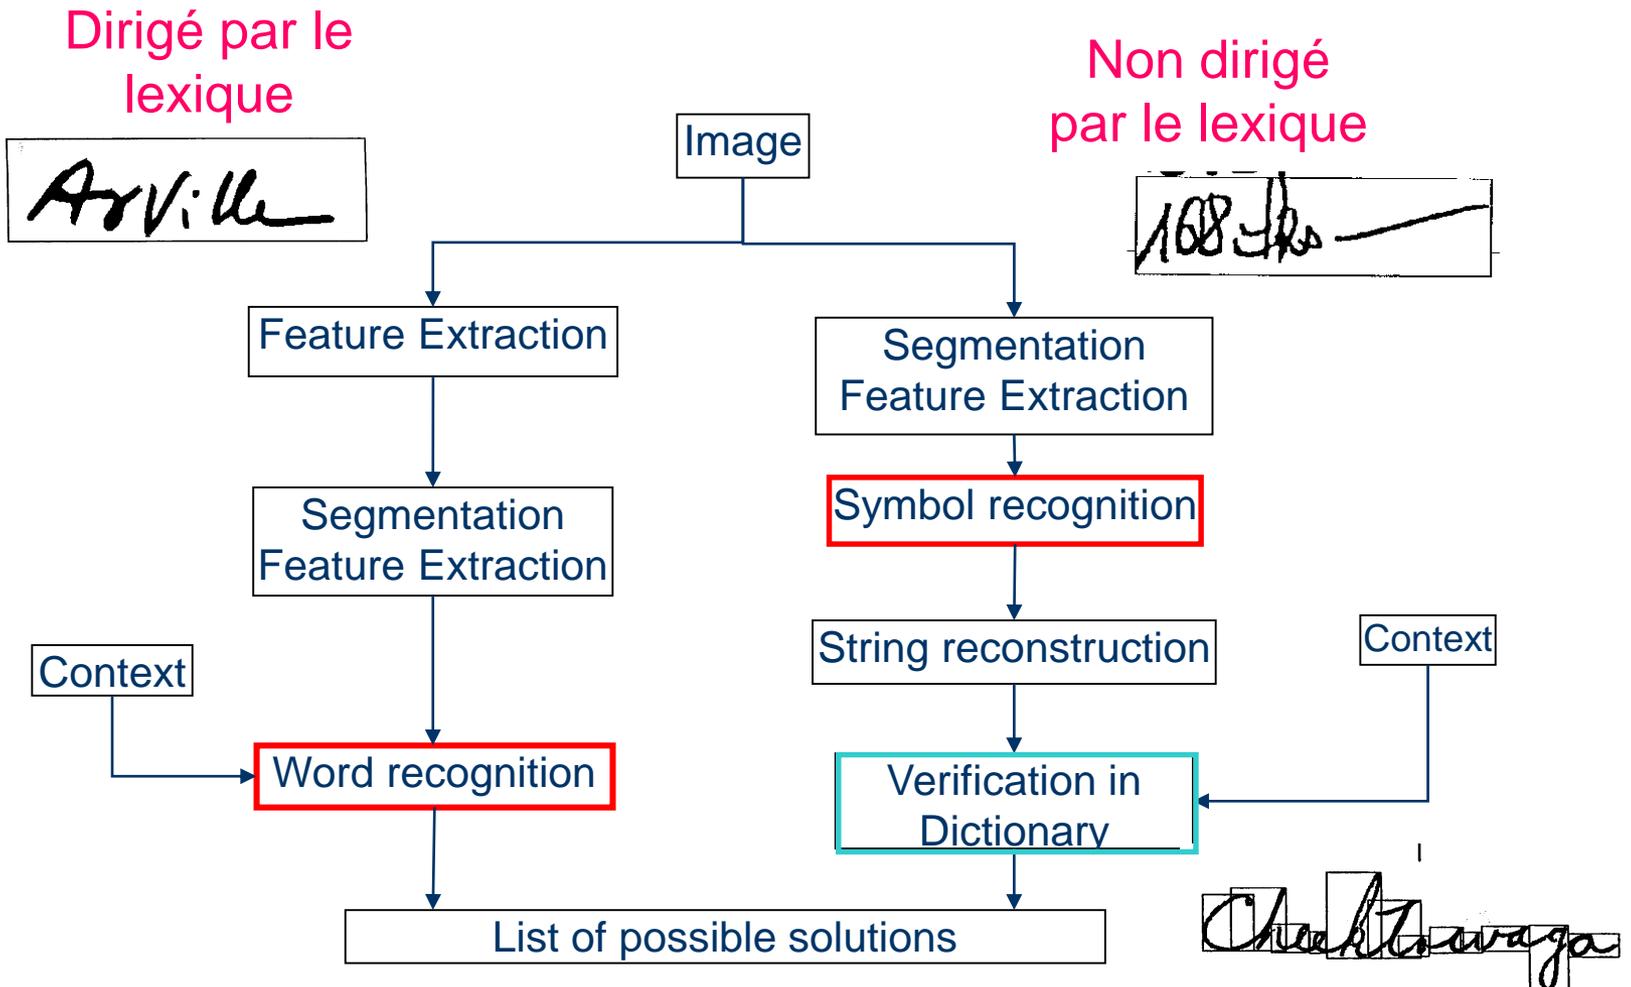
0	0	0	1	0	0	0
1	0	0	0	0	1	0
0	0	0	0	0	1	0
1	0	1	0	1	1	0



Manuscrit : stratégies de segmentation



Manuscrit : stratégies de reconnaissance



Document

- Objectifs de reconnaissance

- Nous avons besoin d'accéder à un ensemble de "documents"
 - Archivage?
 - Indexation?
- Souvent, on a des collections massives et hétérogènes
- Différentes langues
- Différentes présentations
- Différentes sources
- Nous avons de la chance si les métadonnées sont consistantes et uniformes

Document

- Pourquoi acquérir des documents image ?
 - Solution sans papier
 - Transfert efficace
 - Organisation
 - Commodité
 - Accès à une variété de contenus
 - Lecteur universel - courrier électronique, pièces jointes, feuilles de calcul
 - Pas besoin d'applications originales
 - Détecter la falsification : changement du contenu ?
 - Plus facile à certifier?
 - Authentifier le document

Contexte – Objectifs de recherche

Le passé récent

Applications ciblées

Données limitées

Classes connues

Classes figées

Volumétrie faible/moyenne

Aujourd'hui

Problèmes ouverts : courrier libre

Flux continu

Classes évolutives

Pas de connaissance a priori

Volumétrie importante

Modèles statiques

Beaucoup de paramètres

Bases de données locales

Evaluation subjective

Modèles incrémentaux

Paramétrage adaptatif

Bases de données publiques

Métriques pour l'évaluation

Document : comment acquérir ?

- **Balayage?**
 - Haute vitesse, automatisé, multiformes - livres, etc.
- **Photocopieurs numériques**
 - Mémoire d'entreprise
- **Sortie d'application**
 - Imprimer comme l'image
 - Conversion de masse
- **Appareils photo?**
 - Téléphones portables?
 - QipIt, ScanR, Hotcard



Tous ont des implications sur l'utilisation

Document : qu'est ce qu'une image ?

- Représentation pixel de la carte d'intensité
- Pas de "contenu" explicite, que des chiffres les uns à côté des autres
- L'analyse d'image
 - Tente d'imiter le comportement visuel humain
 - Tire des conclusions, formule des hypothèses et vérifie



10 27 33 29
27 34 33 54
54 47 89 60
25 35 43 9

Analyse d'image

Utiliser les techniques adéquates pour représenter le contenu

Transformer les requêtes sémantiques en "caractéristiques d'image"

Couleur, forme, texture ...

Relations spatiales

DAR © A Belaïd

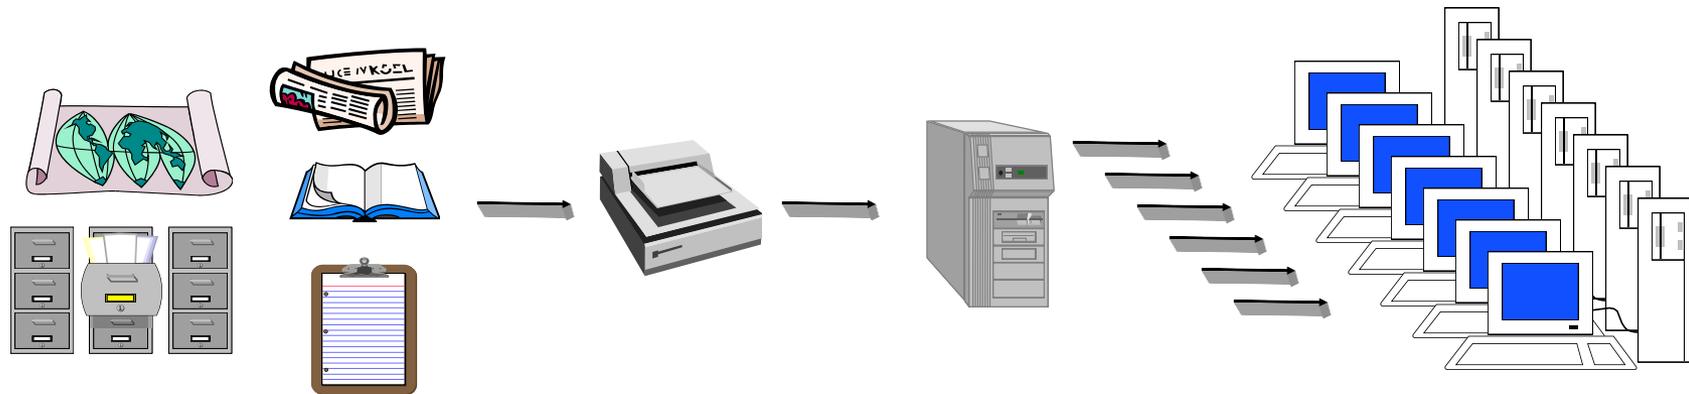
Image de document

- Une collection de points appelés "pixels"
 - Disposés dans une grille appelée "bitmap"
- Pixels souvent binaires (noir, blanc)
 - Mais l'échelle de gris ou la couleur est parfois nécessaire
- 300 points par pouce (ppp) donne les meilleurs résultats
 - Mais les images sont assez grandes (1 Mo par page)
 - Les télécopies sont normalement de 100 à 200 ppp
- Habituellement stocké en format TIFF ou PDF

Pourtant, nous voulons pouvoir les traiter comme des fichiers texte!

Base, dataset...

- Collecte d'images numérisées
- Besoin d'être disponible pour l'indexation et la récupération, l'abstraction, le routage, l'édition, la diffusion, l'interprétation...



Handwritten notes and a diagram on a page from "The Washington Post". The notes include "Please transfer flow a sample of SA" and "10/12/01". A diagram shows a circle with a triangle inside, labeled "10/12/01".

CHARITABLE	ASSET	ACQUISITION DATE	DATE
FIELD BOX (BIBLIOTHEC WERKE)	ANONANAS	FENGSHAPPE	10/19/82
VIAGE (BIBLIOTHEC WERKE)	ARTAFAMA	BUCHN SUPPLEMENT	11/25/82
EAGLE	YOTEMPA	SCHNEN SUPPLEMENT	11/25/82
BALE	INDIAGA	FENBAEDEN	10/24/84
FARE (BIBLIOTHEC WERKE)	INDIAGA MARKETS	COFF	12/07/82/83
STRE. 874 (BIBLIOTHEC WERKE)	BERGEMAN MARKETS	COFF	1/20
STRE. 874 (BIBLIOTHEC WERKE)	BERGEMAN MARKETS	SCHNEN SUPPLEMENT	11/23/82
STRE. 874 (BIBLIOTHEC WERKE)	BERGEMAN MARKETS	COFF	1/20
STRE. 874 (BIBLIOTHEC WERKE)	BERGEMAN MARKETS	SCHNEN SUPPLEMENT	11/23/82
STRE. 874 (BIBLIOTHEC WERKE)	BERGEMAN MARKETS	COFF	1/20
STRE. 874 (BIBLIOTHEC WERKE)	BERGEMAN MARKETS	SCHNEN SUPPLEMENT	11/23/82
STRE. 874 (BIBLIOTHEC WERKE)	BERGEMAN MARKETS	COFF	1/20
STRE. 874 (BIBLIOTHEC WERKE)	BERGEMAN MARKETS	SCHNEN SUPPLEMENT	11/23/82
STRE. 874 (BIBLIOTHEC WERKE)	BERGEMAN MARKETS	COFF	1/20
STRE. 874 (BIBLIOTHEC WERKE)	BERGEMAN MARKETS	SCHNEN SUPPLEMENT	11/23/82
STRE. 874 (BIBLIOTHEC WERKE)	BERGEMAN MARKETS	COFF	1/20
STRE. 874 (BIBLIOTHEC WERKE)	BERGEMAN MARKETS	SCHNEN SUPPLEMENT	11/23/82
STRE. 874 (BIBLIOTHEC WERKE)	BERGEMAN MARKETS	COFF	1/20
STRE. 874 (BIBLIOTHEC WERKE)	BERGEMAN MARKETS	SCHNEN SUPPLEMENT	11/23/82
STRE. 874 (BIBLIOTHEC WERKE)	BERGEMAN MARKETS	COFF	1/20

Handwritten notes and a diagram on a page from "Stadt- und Universitätsbibliothek". The notes include "E 19-71" and "Rau, graphische Zeichen und Zeichen". A diagram shows a circle with a triangle inside, labeled "E 19-71".

Handwritten notes and a diagram on a page from "A a". The notes include "A a" and "A a". A diagram shows a circle with a triangle inside, labeled "A a".

Handwritten notes and a diagram on a page from "A a". The notes include "A a" and "A a". A diagram shows a circle with a triangle inside, labeled "A a".

The Washington Post front page (October 12, 2001). Headlines include: "After Zargawi, No Clear Path In Weary Iraq", "The Young Apprentice", "How U.S. Forces Found Iraq's Most-Wanted Man", and "Kaine Delays Execution Of Inmate For 6 Months".

Handwritten notes and a diagram on a page from "DEUTSCHES PRÄSIDENTENWÄHLER". The notes include "DEUTSCHES PRÄSIDENTENWÄHLER" and "DEUTSCHES PRÄSIDENTENWÄHLER". A diagram shows a circle with a triangle inside, labeled "DEUTSCHES PRÄSIDENTENWÄHLER".

Forbes magazine cover (March 19, 2001). Headline: "THE WORLD'S RICHEST PEOPLE SPECIAL ISSUE". Main title: "Forbes BILLIONAIRES". Subtitle: "HOW FLAVIO BRATTORRE GETS RICH OFF THE LIFESTYLES OF THE SUPER WEALTHY".

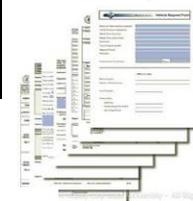
Handwritten notes and a diagram on a page from "A a". The notes include "A a" and "A a". A diagram shows a circle with a triangle inside, labeled "A a".

Financial Times front page (October 12, 2001). Headlines include: "Iraq braced as Saddam rejects Bush ultimatum", "Fed holds rates but signals uncertain future", and "US probes Abdol collusion claims".

D'autres "documents"



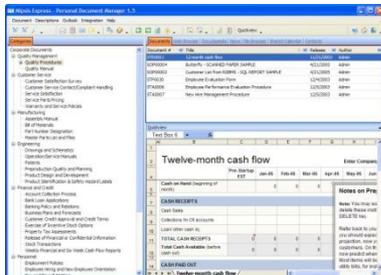
Showroom for
Norsk Wood Works
Fidjeholmen 4 Steigen
For Wood Carving & Furniture
Phone call to: 0047 47 27 20 00
www.norskwoodworks.com



Parliamentary Assembly
Assemblée parlementaire

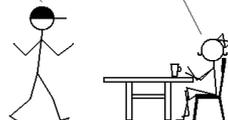


COUNCIL OF EUROPE
CONSEIL DE L'EUROPE



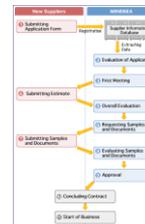
Honey, I think we are beyond the point of me being just your "boyfriend." It's about time you started calling me what I really am.

Your manfriend.



And that is...?

VTU 2004
http://venugopal.blogspot.com



Order online from www.poker-wear.com

Prices always listed are subject to change without notice.

Poker Tables from Poker-Wear

You can't play poker without a poker table and Poker-Wear.com has a great selection of folding poker tables you can use at home. The poker tables are also great for the road. You can have those great looking poker tables set up at all times.

Poker-Wear.com offers a lifetime **FREE SHIPPING** on **poker tables** throughout the US & Canada. This is a limited time offer. Order your Poker-Wear poker table today.

Poker Table
Poker-Wear.com has a great selection of folding poker tables you can use at home. The poker tables are also great for the road. You can have those great looking poker tables set up at all times.

Poker Table
Poker-Wear.com has a great selection of folding poker tables you can use at home. The poker tables are also great for the road. You can have those great looking poker tables set up at all times.

Poker Table
Poker-Wear.com has a great selection of folding poker tables you can use at home. The poker tables are also great for the road. You can have those great looking poker tables set up at all times.

Poker Table
Poker-Wear.com has a great selection of folding poker tables you can use at home. The poker tables are also great for the road. You can have those great looking poker tables set up at all times.

Poker Table
Poker-Wear.com has a great selection of folding poker tables you can use at home. The poker tables are also great for the road. You can have those great looking poker tables set up at all times.

Poker Table
Poker-Wear.com has a great selection of folding poker tables you can use at home. The poker tables are also great for the road. You can have those great looking poker tables set up at all times.

Poker Table
Poker-Wear.com has a great selection of folding poker tables you can use at home. The poker tables are also great for the road. You can have those great looking poker tables set up at all times.

Poker Table
Poker-Wear.com has a great selection of folding poker tables you can use at home. The poker tables are also great for the road. You can have those great looking poker tables set up at all times.

Poker Table
Poker-Wear.com has a great selection of folding poker tables you can use at home. The poker tables are also great for the road. You can have those great looking poker tables set up at all times.

Poker Table
Poker-Wear.com has a great selection of folding poker tables you can use at home. The poker tables are also great for the road. You can have those great looking poker tables set up at all times.

Poker Table
Poker-Wear.com has a great selection of folding poker tables you can use at home. The poker tables are also great for the road. You can have those great looking poker tables set up at all times.

Poker Table
Poker-Wear.com has a great selection of folding poker tables you can use at home. The poker tables are also great for the road. You can have those great looking poker tables set up at all times.

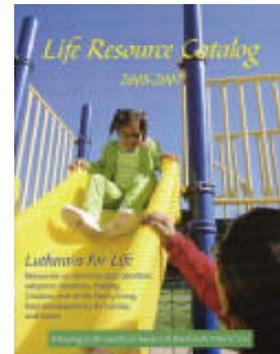
Poker Table
Poker-Wear.com has a great selection of folding poker tables you can use at home. The poker tables are also great for the road. You can have those great looking poker tables set up at all times.

Poker Table
Poker-Wear.com has a great selection of folding poker tables you can use at home. The poker tables are also great for the road. You can have those great looking poker tables set up at all times.

Poker Table
Poker-Wear.com has a great selection of folding poker tables you can use at home. The poker tables are also great for the road. You can have those great looking poker tables set up at all times.

Poker Table
Poker-Wear.com has a great selection of folding poker tables you can use at home. The poker tables are also great for the road. You can have those great looking poker tables set up at all times.

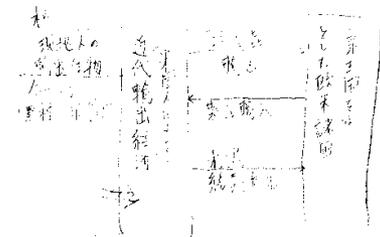
Poker Table
Poker-Wear.com has a great selection of folding poker tables you can use at home. The poker tables are also great for the road. You can have those great looking poker tables set up at all times.



II. 遂上國の社会経済的特徴

1. 基本的核心 - 發展型二重經濟

人口の集中と經濟構造の二重性、山口村地型と二重經濟の呼称が、
これ、他に人口集中地(本村)の発展(元)が各々の発展に急速に
自給外、山口村地型經濟を形成する。



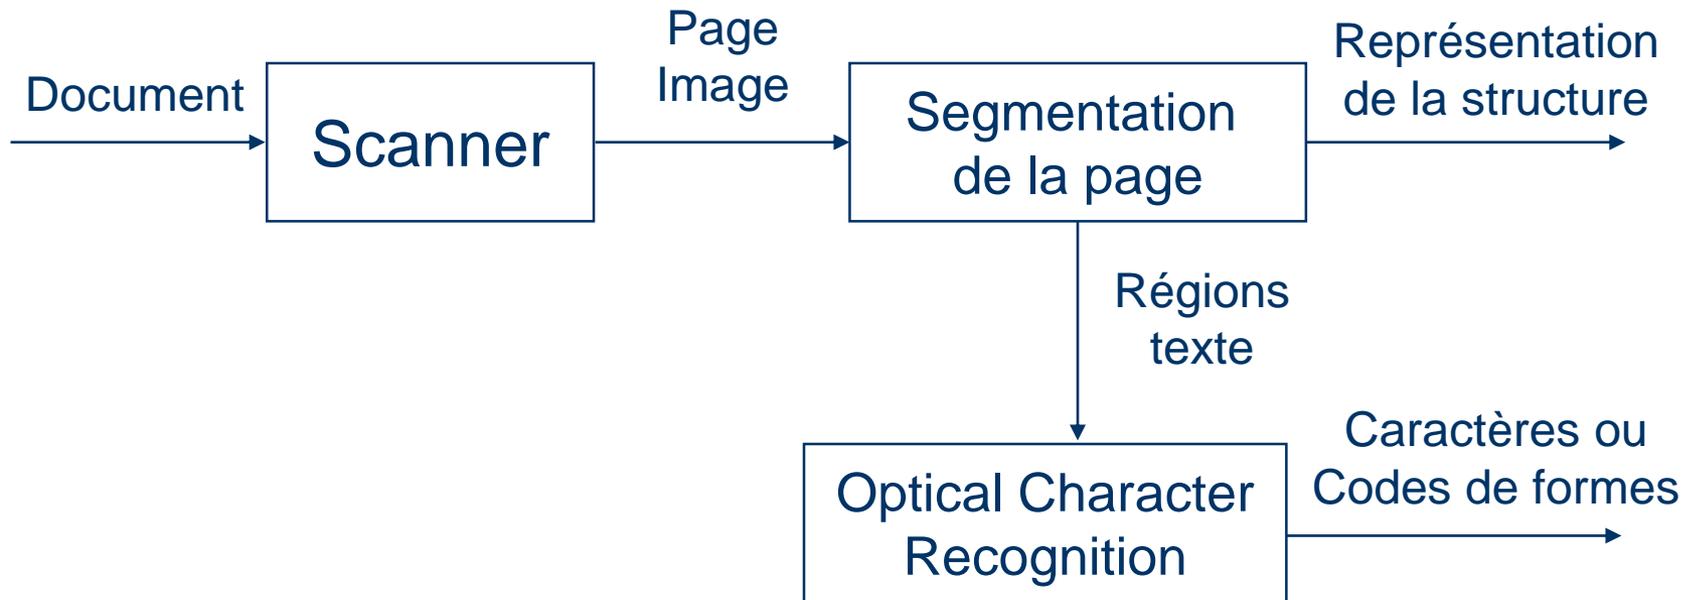
第一地型經濟は、本村の人口集中地を軸として、山口村地型
の二重經濟を形成する。山口村地型は、本村の人口集中地を軸として、
山口村地型を形成する。山口村地型は、本村の人口集中地を軸として、

6. The Three Kingdoms and the Six Dynasty

- 985 ferment n. 불안, 동요, 정치적 동요
- usurp v. 강탈하다
- incessant a. 끊임없는
- shrink v. 줄어듦, 축소되다, 기가 죽다 (p.p. shrunk)
- rashly ad. 무모하게, 성급하게, 성급하게
- massacre v. 학살하다
- flee v. 갈아나다, 도피하다 (p. fled)
- tribe n. 부족, 종족
- abandon v. 버리다, 포기하다
- nomadic a. 유목민적, 유목 생활을 하는
- + Sinicize v. 중국화하다, 중국식으로 만들다
- country n. 기병대, 기마부대
- refugee n. 망명자, 피난자, 난민
- perpetual a. 영구한, 부단한
- tormoil n. 혼란, 동요, 불안
- 987 undermin v. 약화시키다, 서서히 무너시키다
- + monastery n. 수도원, 사원, 선원(僧)
- vast a. 광대한, 거대한, 엄청난
- + proportion n. 크기, 비례, 비등
- realm n. 왕국, 영토
- 1/ realm
- bureaucracy n. 관료제, 관료사회, 관료주의
- + exert v. (힘, 권력 등) 행사하다, (당당) 버티다
- < Taoism > 도교
- Taoism n. 도교
- + calligraphy n. 서예, 서도, 필법, 필적
- conglomeration n. 융합, 결합

Indexation d'images de pages

(Schéma de conversion traditionnel)

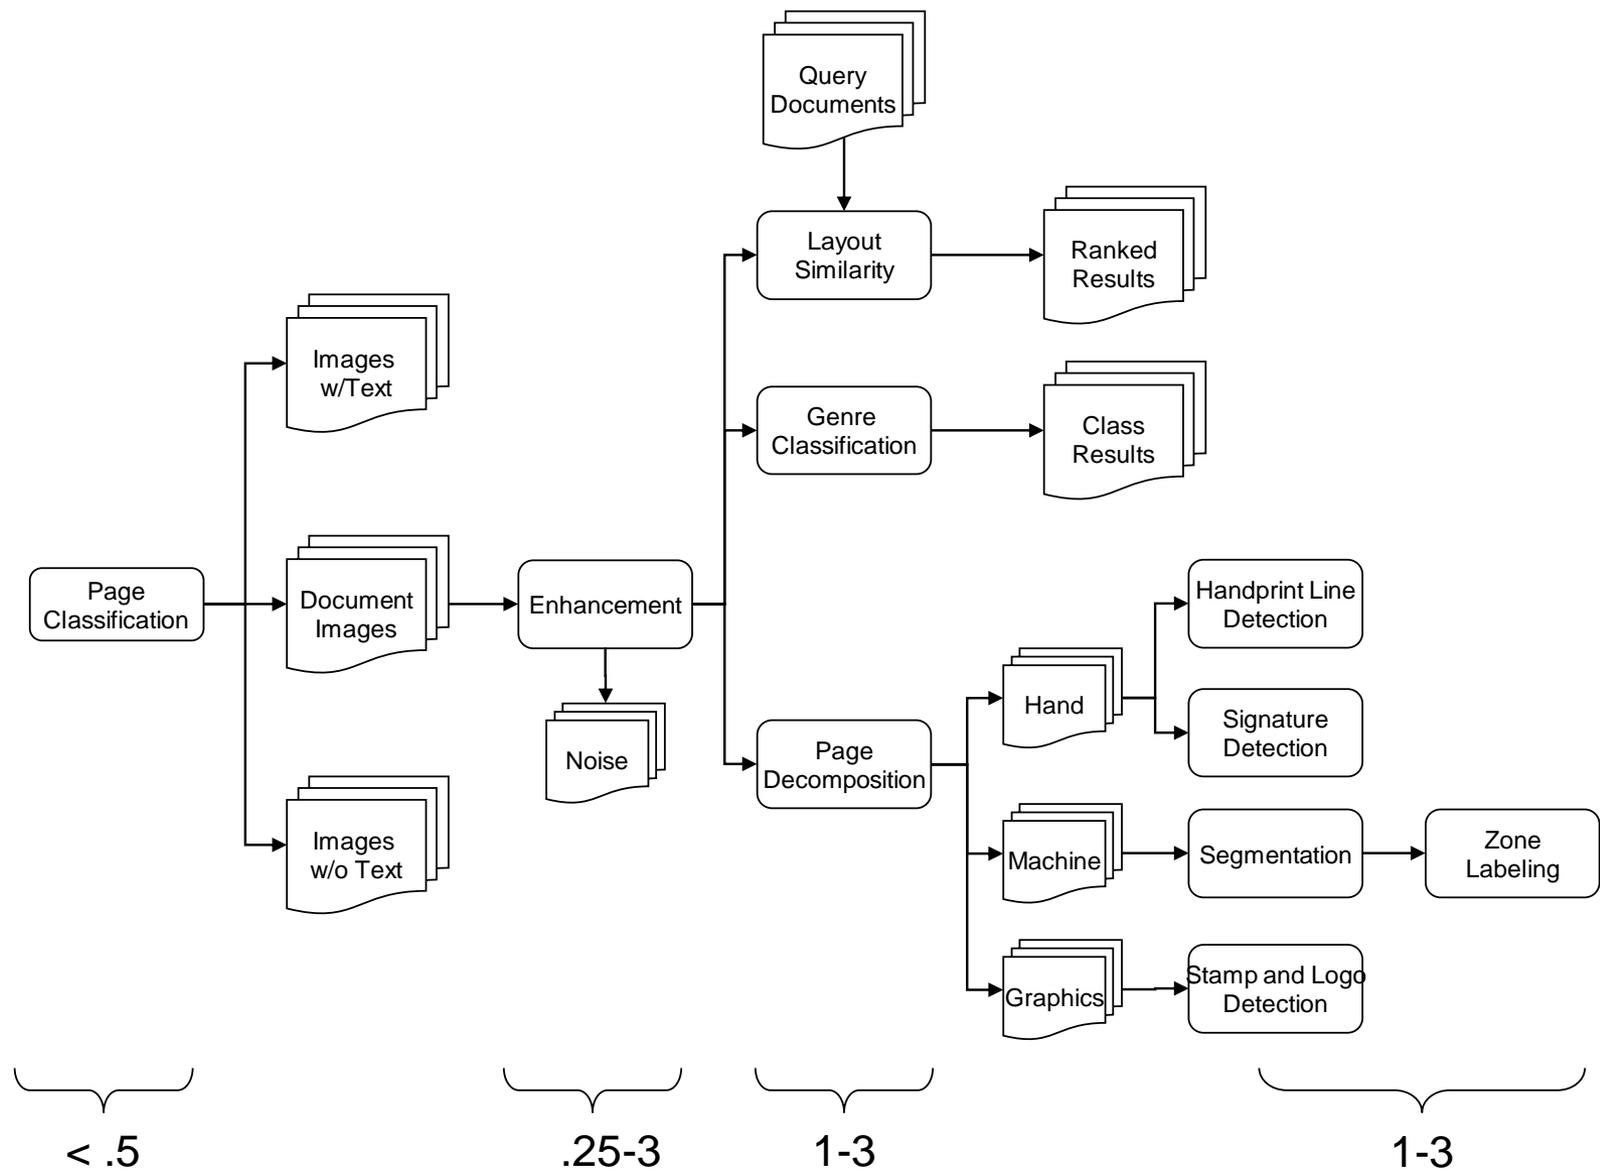


Analyse de l'image du document

- **Schéma général**
 - Acquisition de l'image – digitalisation
 - Prétraitement
 - Extraction de paramètres
 - Classification
- **Tâches spécifiques**
 - Analyse de la structure physique et logique de la page
 - Classification de zones
 - Identification de la langue
 - Traitement spécifique d'une zone
 - Reconnaissance
 - Vectorisation

Analyse de l'image du document

- Ce que vous devez faire avant de pouvoir traiter les images sous forme de "documents électroniques"
 - Analyse de l'image du document
 - Décomposition de la page
 - Reconnaissance optique de caractères
 - Indexation traditionnelle avec conversion
 - Matrice de confusion
 - Codes de forme
 - Faire des choses sans conversion
 - Dépistage, classification, résumé,
 - Repérage des mots clés, etc.



Temps de traitement necessaire en secondes

Pourquoi l'analyse de document est difficile ?

- Plusieurs raisons

- Tableau 2D de “valeurs”
- Représente un langage symbolique
- Beaucoup de variations dans les symboles



- 3-4 fois plus grand que des images normales
- et ça c'est uniquement le cas de documents texte imprimé latin !

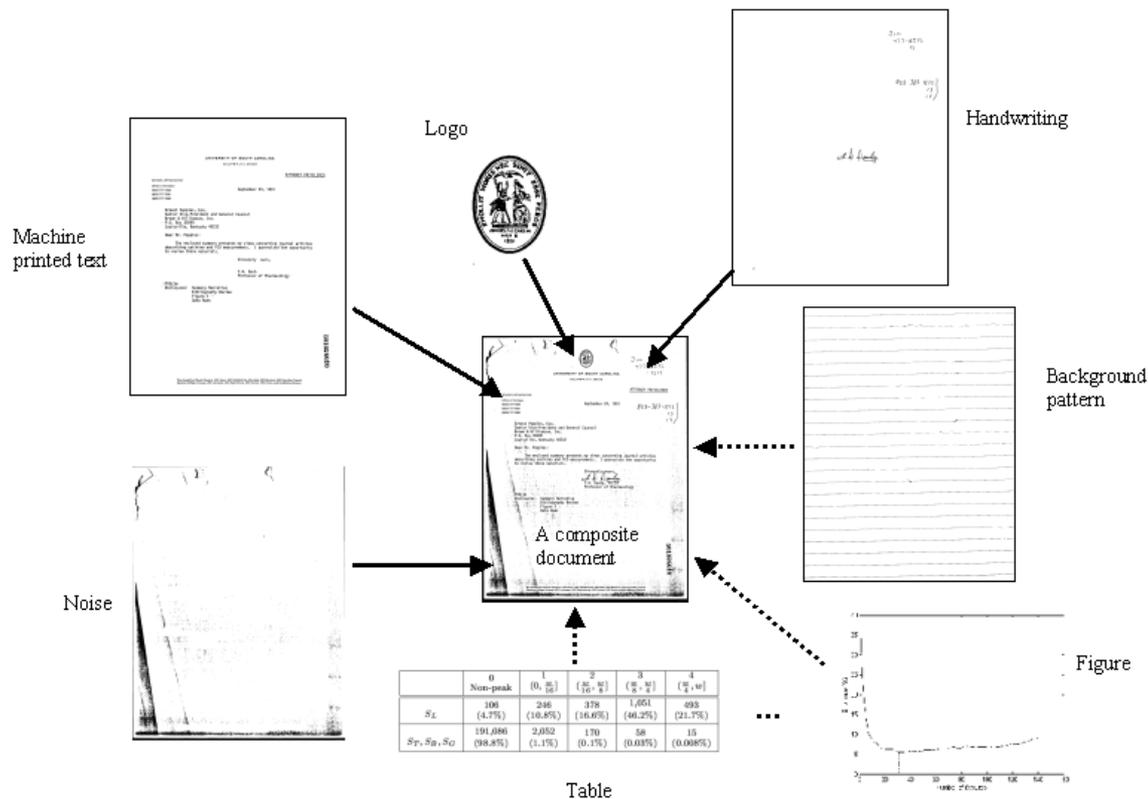
Analyse de page

- En supposant regarder que le texte
 - Correction d'obliquité
 - Basé sur la recherche de l'orientation principale des lignes
 - Détection d'une zone d'image et de texte
 - Basé sur la texture et l'orientation dominante
 - Classification structurelle
 - Infirmer la structure logique de l'agencement physique
 - Classification de la région textuelle
 - Titre, auteur, en-tête, bloc de signature, etc.

Segmentation physique de la page

- Couches d'information

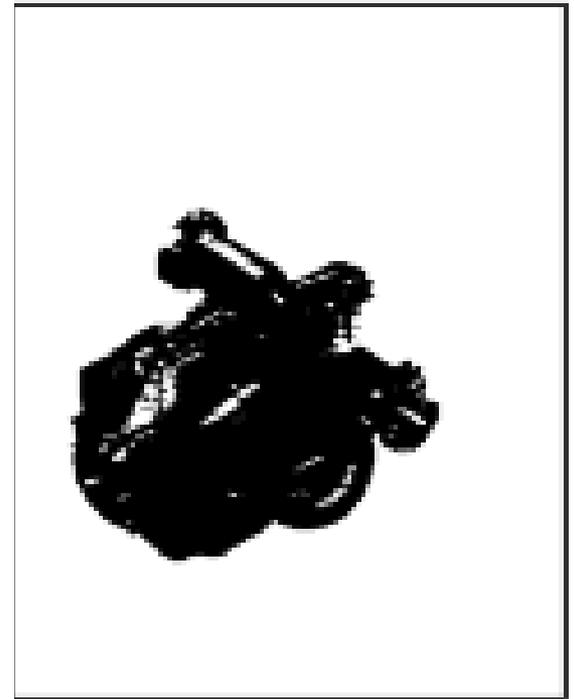
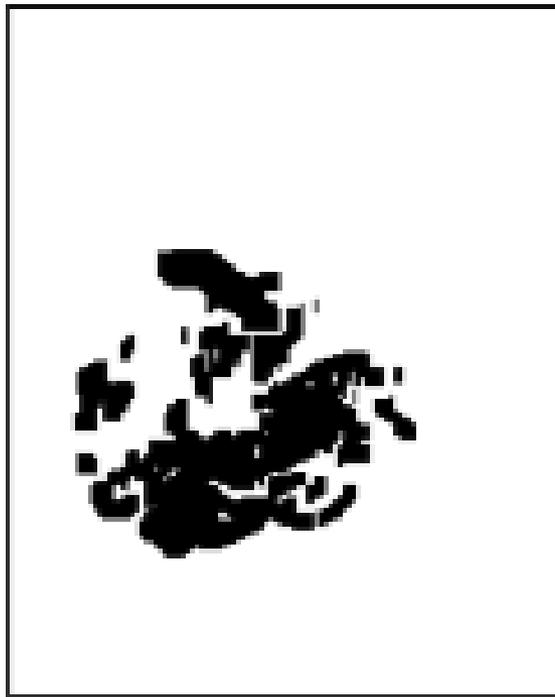
- Un document se compose de plusieurs couches, telles que l'écriture manuscrite, le texte imprimé par machine, les motifs d'arrière-plan, les tableaux, les chiffres, le bruit, etc.



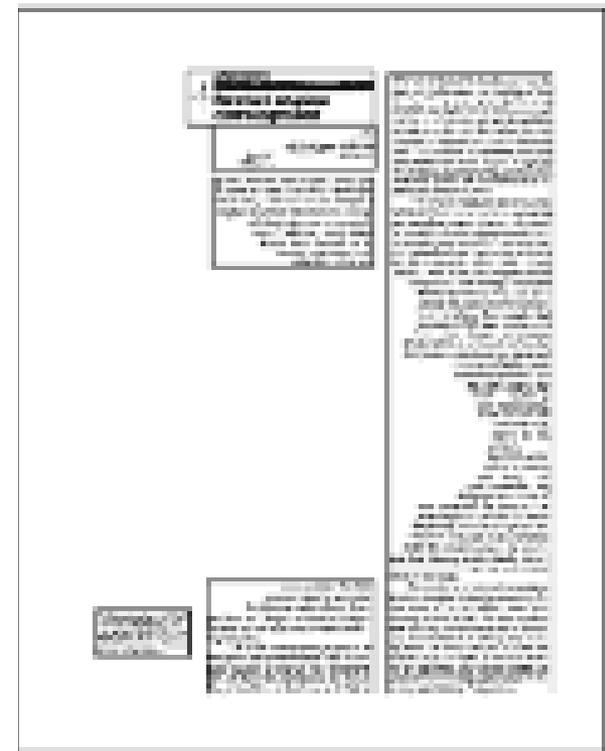
Segmentation de la page

- Généralement basée sur la proximité spatiale
 - Espaces blancs
 - Marges
 - Différences de type de contenu
- Peut être très sensible au bruit
- Distinguer entre
 - Top Down
 - On découvre en décomposant
 - Bottom up
 - On rassemble ce qu'on connaît

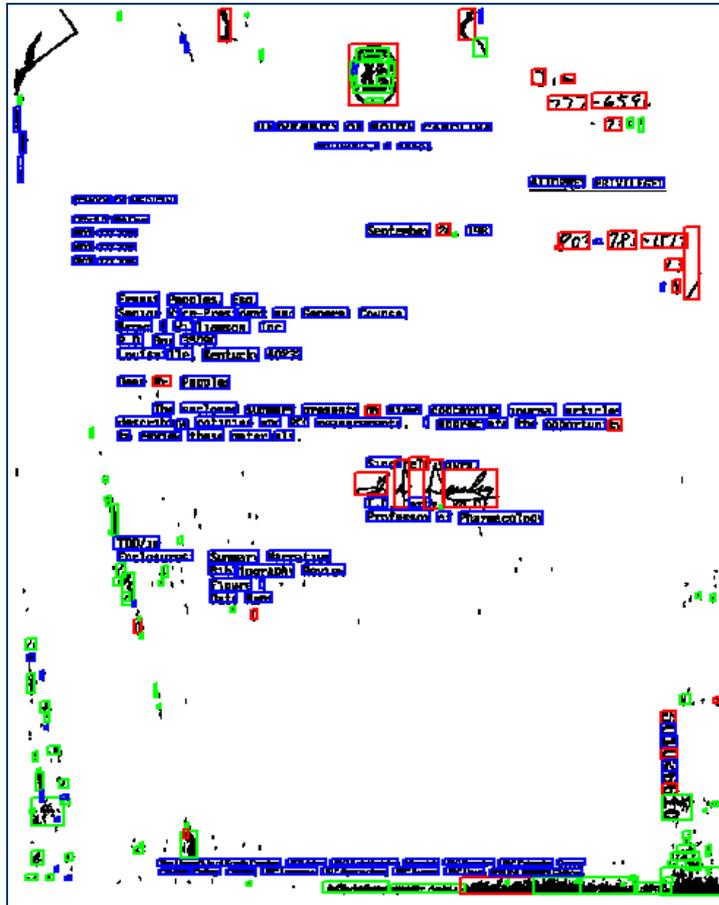
Détection d'objets



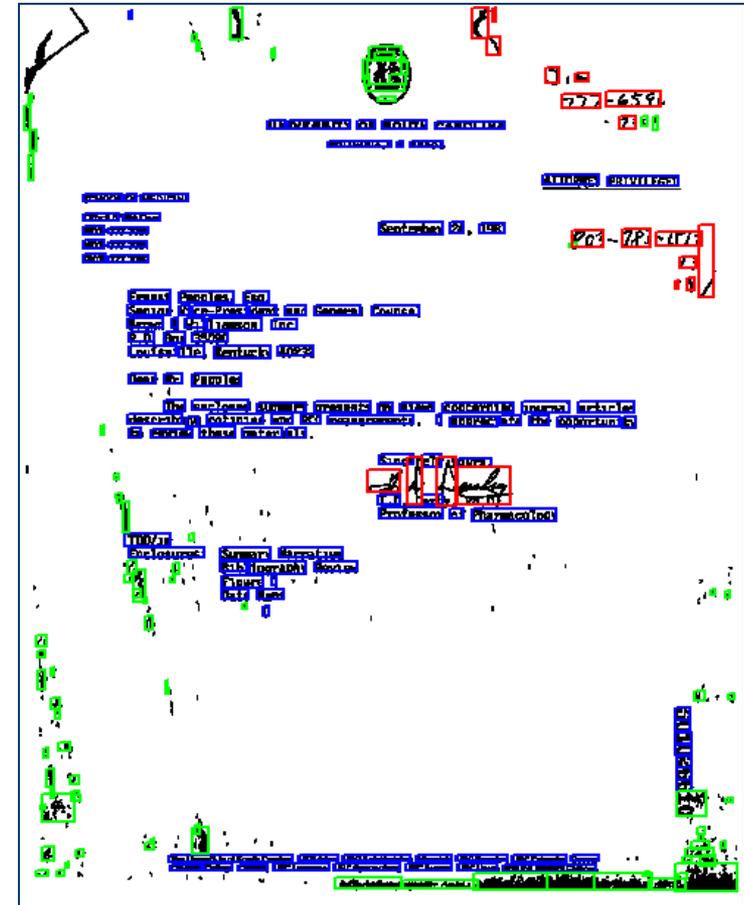
Detection de régions de texte



Un exemple plus complexe



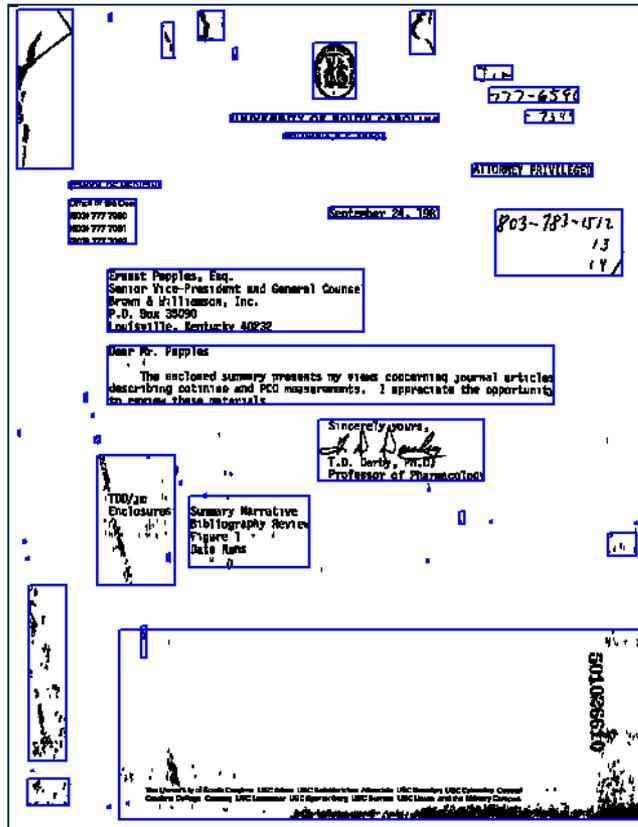
Avant post-traitement par MRF



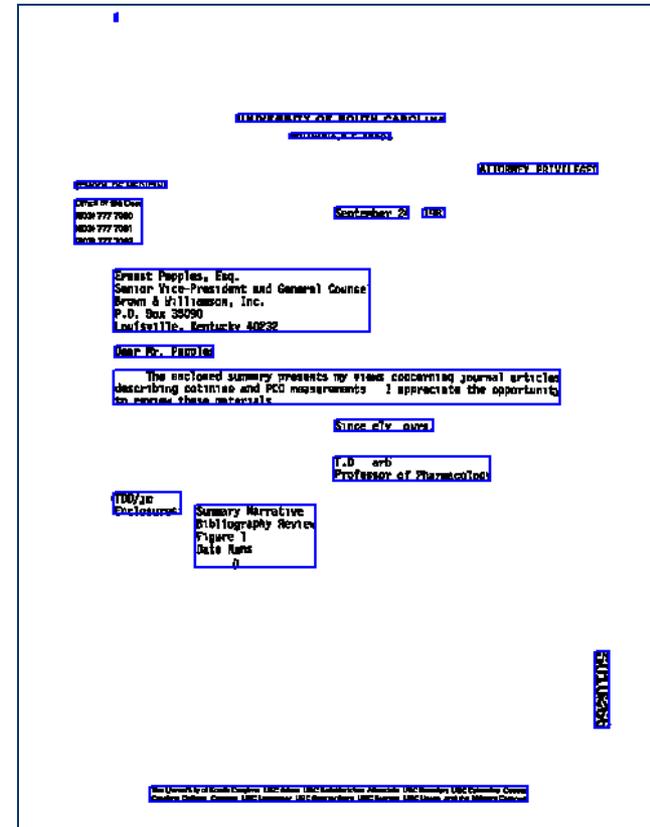
Après post-traitement par MRF

MRF: Markov Random Field: prend en compte le contexte

Application à la segmentation de la page



Avant réhaussement



Après réhaussement

Identification de la langue

- Détection de l'inclinaison indépendamment de la langue
- Accommoder écriture horizontale et verticale
- Reconnaissance de classe de script
- Scripts asiatiques ont des caractères sous forme de blocs
- Les scripts connectés ne peuvent pas être segmentés facilement
- Identification des langues
- Les statistiques de forme fonctionnent bien pour les langues occidentales
- Les classificateurs concurrents fonctionnent pour les langues asiatiques

Qu'en est-il du manuscrit ?

Optical Character Recognition

- **Approche d'appariement de modèles**
 - Approche standard dans les systèmes commerciaux
 - Segmenter les caractères individuels
 - Reconnaître en utilisant un classificateur de type réseau neuronal
- **Approche du modèle de Markov caché**
 - Approche expérimentale développée à BBN
 - Segmenter en tranches de sous-caractères
 - Lookahead limité pour trouver le meilleur choix de caractères
 - Utile pour les scripts connectés (par exemple, l'Arabe)

Problèmes de précision des OCR

- Erreurs de segmentation de caractères
 - En anglais, la segmentation change souvent "m" en "rn"
- Confusion de caractères
 - Les caractères avec des formes semblables sont souvent confondus
- OCR sur les copies est bien pire que sur les originaux
 - coupure de caractère, fission, pliage
- Les polices peu communes peuvent causer des problèmes
 - Si elles ne sont pas utilisées pour l'entraînement du réseau neuronal

Amélioration de la précision des OCRs

- **Prétraitement de l'image**
 - Morphologie mathématique pour la floraison et le fractionnement
 - Particulièrement important pour les images dégradées
- **Le «vote» entre plusieurs moteurs OCR**
 - Les systèmes individuels dépendent de données de formation spécifiques
- **L'analyse linguistique peut corriger certaines erreurs**
 - Utilisez les statistiques de confusion, les listes de mots, la syntaxe, ...
 - Mais des erreurs plus nocives pourraient être introduites

Vitesse des OCR

- Les réseaux neuronaux prennent environ 10 secondes par page
 - Les modèles de Markov cachés sont plus lents
- Le vote peut améliorer la précision
 - Mais à une vitesse de pénalité substantielle
- Facile à accélérer les choses avec plusieurs machines
 - Par exemple, par traitement par lots - utilisant des ordinateurs de bureau la nuit

Problème : analyse logique de la page (ordre de lecture)

- Peut être difficile à deviner dans certains cas
 - Colonnes de journaux, légendes, appendices, ...
- Parfois, il existe des guides explicites
 - «Suite à la page 4» (mais la page 4 peut être grande!)
- Les repères structurels peuvent aider
 - La colonne 1 pourrait continuer à la colonne 2
- L'analyse de contenu est également utile
 - Statistiques de cooccurrence de mots, analyse de syntaxe

Document : traitement

- **Intégration de la connaissance métier**

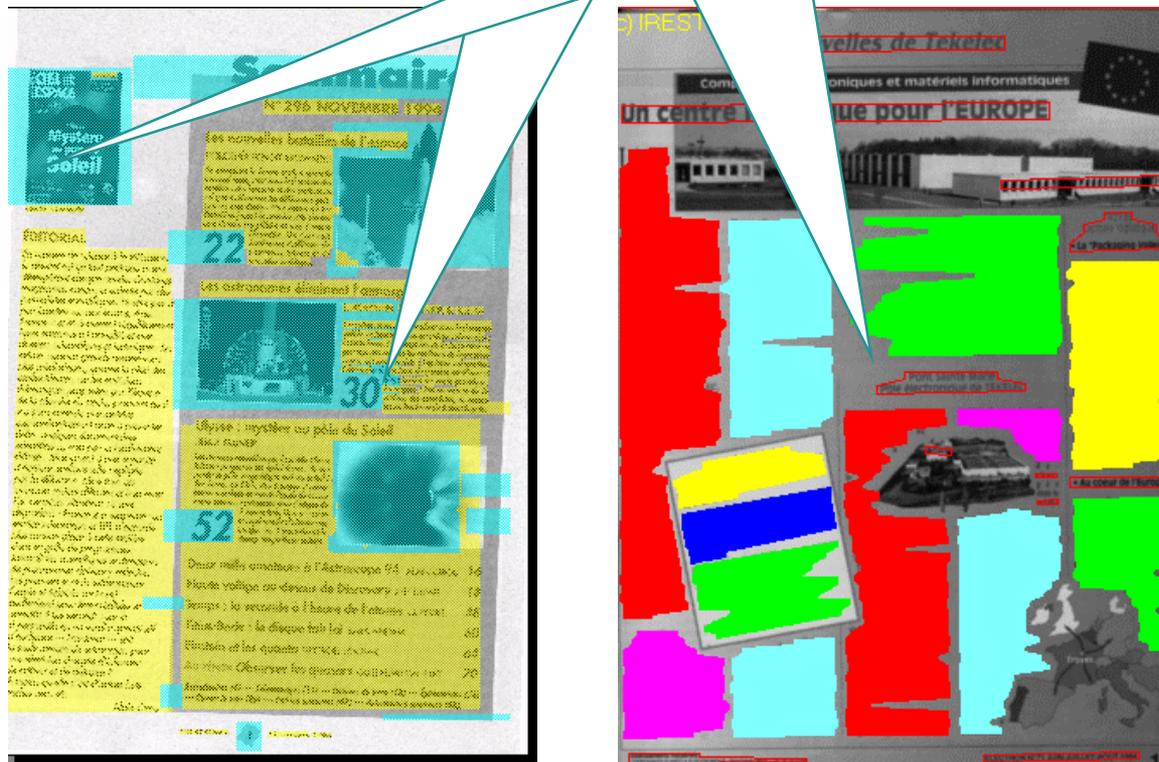
- Un document est destiné à véhiculer un message
- Pour faciliter la compréhension, des efforts ont été faits pour uniformiser les documents avec un certain nombre de conventions :
 - Sur la langue, les formes de caractères, la typographie (style, police, mise en page ...), la structure des documents
 - Selon la fonction du document, il existe différentes conventions d'écriture et de présentation
 - Besoin de reconnaître le type de document
 - Peu de travaux sur l'identification du type de document pour appliquer une reconnaissance appropriée
- Le critère de choix est important !

Exemple 1:

Choix d'un critère pour la séparation texte/image

- Critère : un texte est composé d'alignements de caractères

Erreurs de segmentation



➔ Le manque de familiarité avec les difficultés réelles

Exemple 2 :

Séparation Texte / Formules

- **Critère** : une formule est composée de blocs isolés du texte

La deuxième solution est soit $> a$ si $a < 2$, soit < 0 si $a > 2$ ce qui semble implicitement exclu. Je ne retiens que la première solution. La formule trouvée convient aussi dans le cas où $a = 2$. Nous avons donc :

$$b = \varphi(a) = \frac{2a}{2+a} \quad r' = \frac{a^2}{4} \quad r'' = \frac{b^2}{4}.$$

b) L'intervalle $]0, \infty[$ est stable par la fonction φ ; la suite (a_n) est donc bien définie et à valeurs dans $]0, \infty[$. Comme sur cette intervalle $\varphi(x) < x$, pour tout n , $a_{n+1} = \varphi(a_n) < a_n$.

La suite (a_n) est donc strictement décroissante et minorée par 0, donc convergente vers un nombre ≥ 0 . Ce nombre L doit vérifier, puisque φ est continu sur $]0, \infty[$, $\varphi(L) = L$, ce qui implique $L = 0$. La suite (a_n) est donc strictement positive, strictement décroissante de limite nulle.

Critère insuffisant

La deuxième solution est soit $> a$ si $a < 2$, soit < 0 si $a > 2$ ce qui semble implicitement exclu. Je ne retiens que la première solution. La formule trouvée convient aussi dans le cas où $a = 2$. Nous avons donc :

$$b = \varphi(a) = \frac{2a}{2+a} \quad r' = \frac{a^2}{4} \quad r'' = \frac{b^2}{4}.$$

b) L'intervalle $]0, \infty[$ est stable par la fonction φ ; la suite (a_n) est donc bien définie et à valeurs dans $]0, \infty[$. Comme sur cette intervalle $\varphi(x) < x$, pour tout n , $a_{n+1} = \varphi(a_n) < a_n$.

La suite (a_n) est donc strictement décroissante et minorée par 0, donc convergente vers un nombre ≥ 0 . Ce nombre L doit vérifier, puisque φ est continu sur $]0, \infty[$, $\varphi(L) = L$, ce qui implique $L = 0$. La suite (a_n) est donc strictement positive, strictement décroissante de limite nulle.

Exemple 2 :

Séparation Texte / Formules

- **Critère 2 :** Une formule est située dans le texte parce qu'elle est constituée :
 - De blocs de texte isolés
 - Ou d'éléments du texte autour de marques comme ('=', '<', '[', ']'), des chiffres, des lettres grecques, des mots clés comme 'série', 'fonction' ...)
 - Ou de composantes spécifiques généralement dans les grandes formules

Critère suffisant

La deuxième solution doit $> a$ si $a < 2$, soit < 0 si $a > 2$ ce qui semble implicitement exclu. Je ne retiens que la première solution. La formule trouvée convient aussi dans le cas où $a = 2$. Nous avons donc :

$$b = \varphi(a) = \frac{2a}{2+a} \quad r' = \frac{a^2}{4} \quad r'' = \frac{b^2}{4}.$$

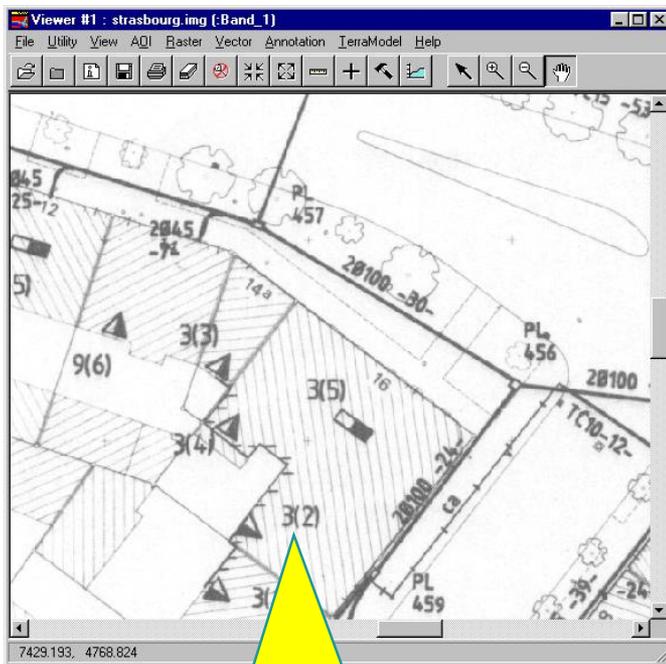
b) L'intervalle $]0, \infty[$ est stable par la fonction φ ; la suite (a_n) est donc bien définie et à valeurs dans $]0, \infty[$. Comme sur cette intervalle $\varphi(x) < x$, pour tout n , $a_{n+1} = \varphi(a_n) < a_n$.

La suite (a_n) est donc strictement décroissante et minorée par 0, donc convergente vers un nombre ≥ 0 . Ce nombre L doit vérifier, puisque φ est continu sur $]0, \infty[$, $\varphi(L) = L$, ce qui implique $L = 0$. La suite (a_n) est donc strictement positive, strictement décroissante de limite nulle.

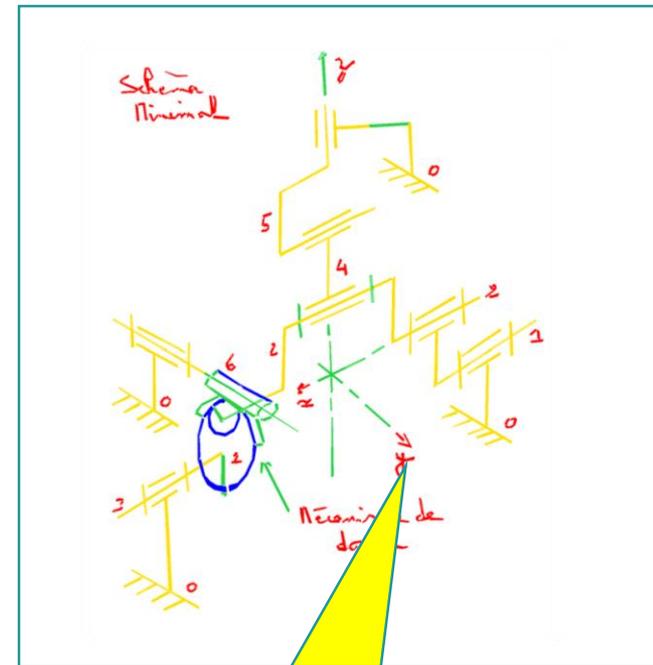
Exemple 3 :

Séparation Texte / Graphique

- **Critère :** Le texte est composé de composantes connexes éloignées des longs traits



Critère suffisant



Critère insuffisant

Exemple 4 :

Séparation Texte / Vidéo

- **Critère :** Le texte est formé de composantes connexes alignées de la même couleur qui apparaissent sur plusieurs images consécutives



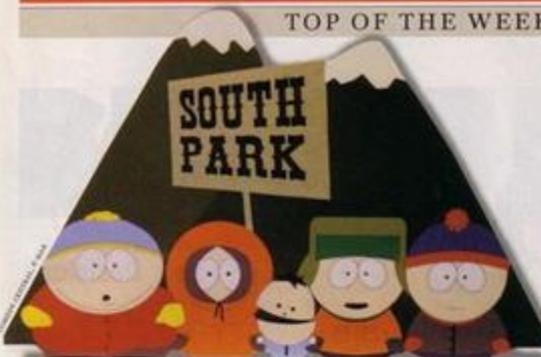
Critère suffisant



Critère insuffisant

Extraction d'information

TOP OF THE WEEK



SOUTH PARK

THE COVER: A twisted underground cartoon is now a pop-cult obsession. Welcome to 'South Park,' a paranormal Colorado town inhabited by flatulent third-graders—a grown-up show with irresistible kid appeal. **Page 56**



INTERNATIONAL: The inside story of how the CIA's secret war in Iraq turned into a fiasco. **Page 36**



SOCIETY: For a day, an asteroid threatened the globe. Then the scientists checked their math. **Page 52**



NATIONAL AFFAIRS: Why Linda Tripp sold out a friend—and ignited a scandal. **Page 22**

COVER: Artwork by South Park/Comedy Central.

Newsweek

Letters to the Editor should be sent to Newsweek, 251 West 57th Street, New York, NY 10019-2101. In the U.S. and subsequent regions to Newsweek, P.O. Box 5186, Boulder, CO 80522-0867. Newsweek ISSN 0251-9045, March 25, 1998. Follow CXXX, No. 25. In Canada and subsequent regions to Newsweek, Inc., P.O. Box 4022, Postal Station 6, Toronto, Ontario M5W 1K1. Canada Post International Publications Mail Classification Distribution Sales Agreement No. 246908. Canadian GST No. R12302-000. For all changes of address call 1-800-454-4836. For all other inquiries call 1-800-451-4041. Unless otherwise indicated by asterisk or acronym designation, all terms and prices are applicable in the U.S. only and may not apply in Canada. Newsweek is published weekly, except for 2 issues combined into one at year-end, for U.S. subscribers please print on the back cover. For advertising rates and information, call 1-800-451-4041. POSTMASTER: send address changes to Newsweek, P.O. Box 5186, Boulder, CO 80522-0867. © 1998 Newsweek Inc.

NATIONAL AFFAIRS

White House: The Linda Tripp Mystery by Evan Thomas, Martha Brant and Pat Wingert 22

Kathleen Willey and the Mogul From Jones v. Clinton; 'No Curtains on the Oval Office' Ginsburg, Lawyer in the Limelight; The Vice Boss Kenneth Starr 27

James McDougal: Remembering a Southern Rogue by Curtis Wilkie 35

INTERNATIONAL

Exclusive: The CIA's War in Iraq by Evan Thomas, Christopher Dickey and Gregory L. Vintou 36

Tale of a Turncoat 43

Nicaragua: Ortega Faces a Charge 46

BUSINESS

Wall Street: Combining Amex and Nasdaq by Allen Sloan and Leslie Kaufman 49

China: Relations on a Roll 50

Judgment Calls: Our Boom Meets Asia's Crisis by Robert J. Samuelson 51

SOCIETY

Science: Worlds May Not Collide by Adam Rogers and Sharon Begley 52

Education: Do Single-Sex Schools Help 55

THE ARTS

The Cover: The Rude Tube by Rick Marin 56

Issue: Hayes Is Back 60

Movies: Funny, Sad 'Primary Colors' Dilegio in the 'Iron Mask' 63

Books: The 'Satan' and 'Hitler' 64

Theater: 'M. Butterfly' 67

Books: Science Fiction Marriage 69

FOCUS ON MONEY

Stocks: Trouble for Tech Leaders 70

Mutual Funds: Watch Those Funds 73

'Leading Questions': How the IRS Finds You by Jane Bryant Quinn 74

DEPARTMENTS

Pariscope 4 Perspectives 21

Cyberscope 8 Newsmakers 47

Millennium 12 'The Last Word' by Letters 15 Meg Greenfield 76

My Turn 19

The structure

Typographical context

INTERNATIONAL
Exclusive: The CIA's War in Iraq

Textual context

Exclusive: The CIA's War in Iraq **OCR**

Syntactical context

CIA War Iraq
THE Warm Iraq

Logical context

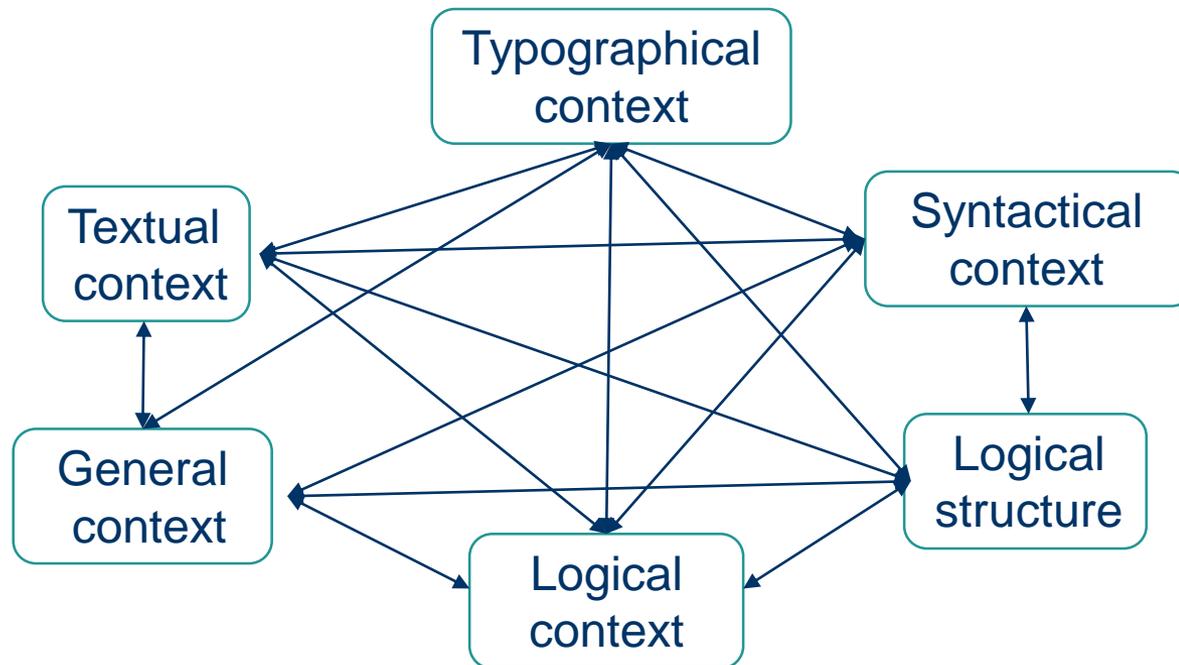
text, abstract, author, reference, n° page, photo, title...

General context

Summary? Letter? Book? Journal paper?

Processus d'extraction d'information

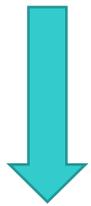
- Utiliser autant d'informations que possible à tous les niveaux
- Problème : l'information est inter-dépendante !



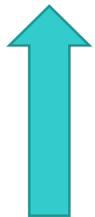
Approche dépendant du niveau sémantique

- Descendante : de la connaissance aux données
- Ascendante : des données à la connaissance
- Mixte: aller-retour entre niveaux

Approche descendante

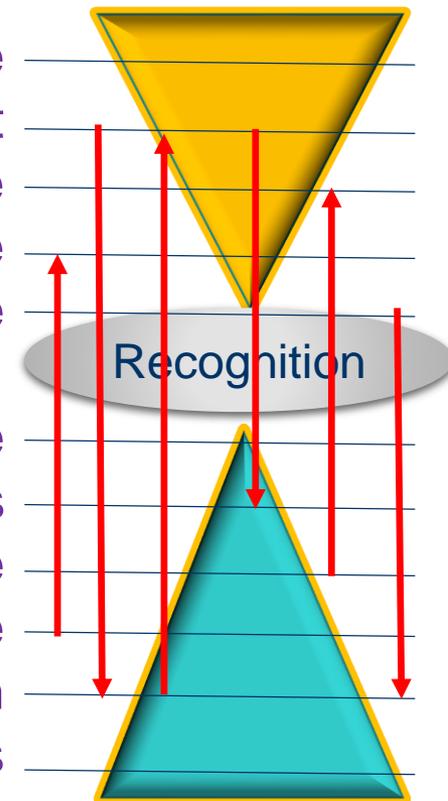


Culture générale
Connaissances particulières sur un document
Structure logique et fonctionnelle
Reconnaissance sémantique
Reconnaissance de texte adaptée

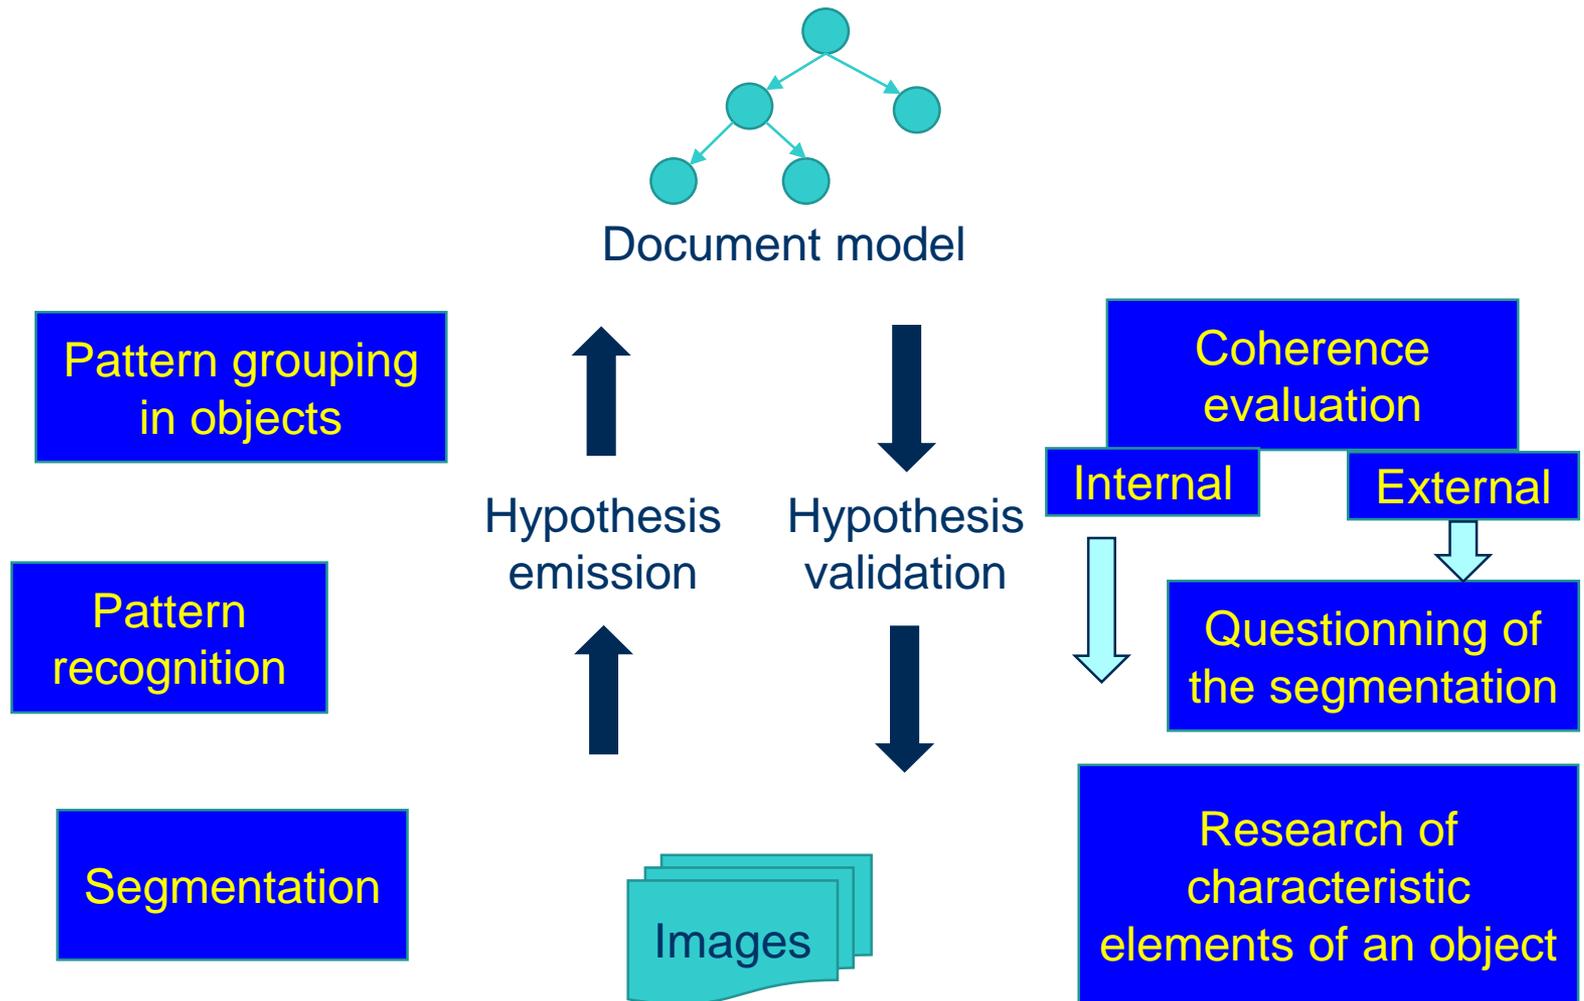


Approcha ascendante

Syntaxe
Reconnaissance de caractères
Typographie
Structure physique
Segmentation
Pixels



Approche utilisant des cycles perceptifs



Retrieval du texte d'OCR

- Nécessite des méthodes d'indexation robustes
- Les méthodes statistiques avec de grands documents fonctionnent le mieux
- Évaluations clés
 - Le succès de la ROC de haute qualité (Croft et al 1994, Taghva 1994)
 - Succès limité pour un OCR de mauvaise qualité (1996 TREC, UNLV)
 - Clustering réussie pour une précision > 85% (Tsuda et al, 1995)

N-Grams

- Méthode statistique puissante et peu coûteuse pour caractériser les populations
- Approche
 - Diviser le document en paires de caractères n : échoue
 - Utiliser des représentations d'indexation traditionnelles pour effectuer des analyses
 - "DOCUMENT" -> DOC, OCU, CUM, UME, MEN, ENT
- Avantages
 - Statistiquement robustes à un petit nombre d'erreurs
 - Indexation rapide et récupération
 - Fonctionne entre 70% et 85% de précision des caractères lorsque l'IR traditionnelle échoue

Matching avec les erreurs OCR

- Au-dessus de 80% de précision des caractères, utilisez des mots
 - Avec correction linguistique
- Entre 75% et 80%, utiliser des n-grammes
 - Avec n un peu plus faible que d'habitude
 - Et peut-être avec des statistiques de confusion de caractère
- En dessous de 75%, utilisez des codes de forme de longueur de mot

Traitement d'images de texte

- **Les caractéristiques**

- Ne nécessite pas de coûteuses opérations d'OCR / Conversion
- Applicable aux applications de filtrage
- Peut être plus résistant au bruit

- **Inconvénients possibles**

- Le domaine d'application peut être très limité
- Le temps de traitement peut être un problème si l'indexation est autrement requise

Keyword Spotting

Techniques:

- Work Shape/HMM - (Chen et al, 1995)
- Word Image Matching - (Trenkle and Vogt, 1993; Hull et al)
- Character Stroke Features - (Decurtins and Chen, 1995)
- 📄 Shape Coding - (Tanaka and Torii; Spitz 1995; Kia, 1996)

Applications:

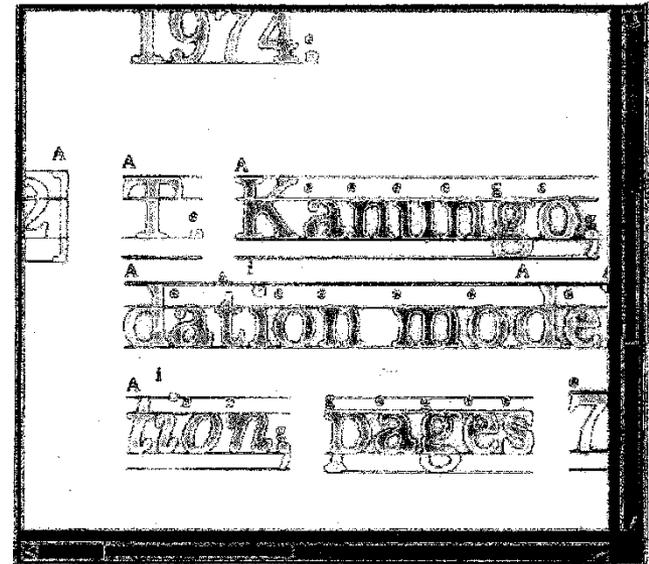
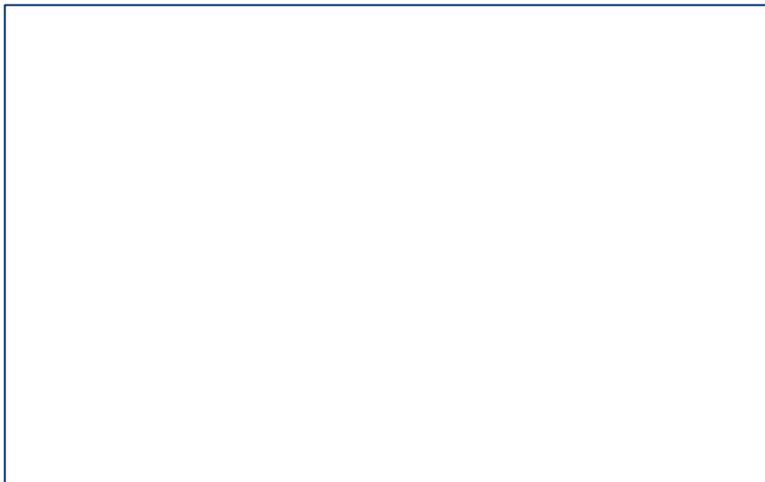
- Filing System (Spitz - SPAM, 1996)
- Numerous IR
- Processing handwritten documents

Evaluation formelle

- Scribble vs. OCR (DeCurtins, SDIUT 1997)

Codage de forme (shape coding)

- Approche
 - Utilisation de descripteurs génériques de caractères
 - Utiliser le pouvoir du langage pour résoudre l'ambiguïté
 - Carte Caractère basé sur les caractéristiques de la forme, y compris les ascendants, les descendants, la ponctuation et le caractère avec des trous



Applications supplémentaires

- **Manuscrits d'archives manuscrits**
 - (Manmatha, 1997)
- **Classification de pages**
 - (Decurtins et Chen, 1995)
- **Correspondance des enregistrements manuscrits**
 - (Ganzberger et coll., 1994)
- **Extraction des titres**
 - Compression d'images de documents (UMD, 1996-1998)

Une application industrielle

Traitement des formulaires



Le traitement des formulaires

- **Aujourd'hui, un vrai marché**
 - **Concerne toutes les administrations et les services**
 - qui manipulent de l'information de masse
 - salaires, factures...
 - plusieurs milliers par jour
 - **Il existe des bases métiers**
 - très riches et très spécifiques
 - plusieurs millions d'enregistrements
 - qui peuvent aider au traitement automatique

L'analyse du marché

les clients potentiels

Applications	Clients potentiels (France)	Nb de sites	Nb de clients potentiels
Assurance maladie	CPAM, MSA, ...	700	700
Allocations familiales	CAF	100	100
Retraite	CRAM, Caisses de Retraites privées et publiques,...	500	200
Agences pour l'emploi	ANPE, APEC, ASSEDIC, et bureaux locaux	500	100
Services publics locaux (écoles, élections, sports, ...)	Mairies	36000	1500
Services publics locaux (RMI, transports scolaires, ...)	Conseils Généraux et Régionaux	100	100
Services publics locaux (création d'entreprise, ...)	Chambres de Commerce, des Métiers, d'Agriculture	400	200
Services publics locaux (passeports, cartes d'identité, cartes grises, ...)	Préfectures, Sous Préfectures	150	150
Taxes locales	Percepteur, Centres des Impôts, Douanes, ...	300	100
Education et formation continue	Universités, centres de formation, ...	500	100
Santé	Hôpitaux, cliniques, centres médicaux, ...	500	100
Services de la relation clientèle	Grandes entreprises, Banques, Assurances, Opérateurs, sociétés de BtoC	10000	1000
	Total	49750	4350

Analyse du marché

Des spécialistes de la dématérialisation

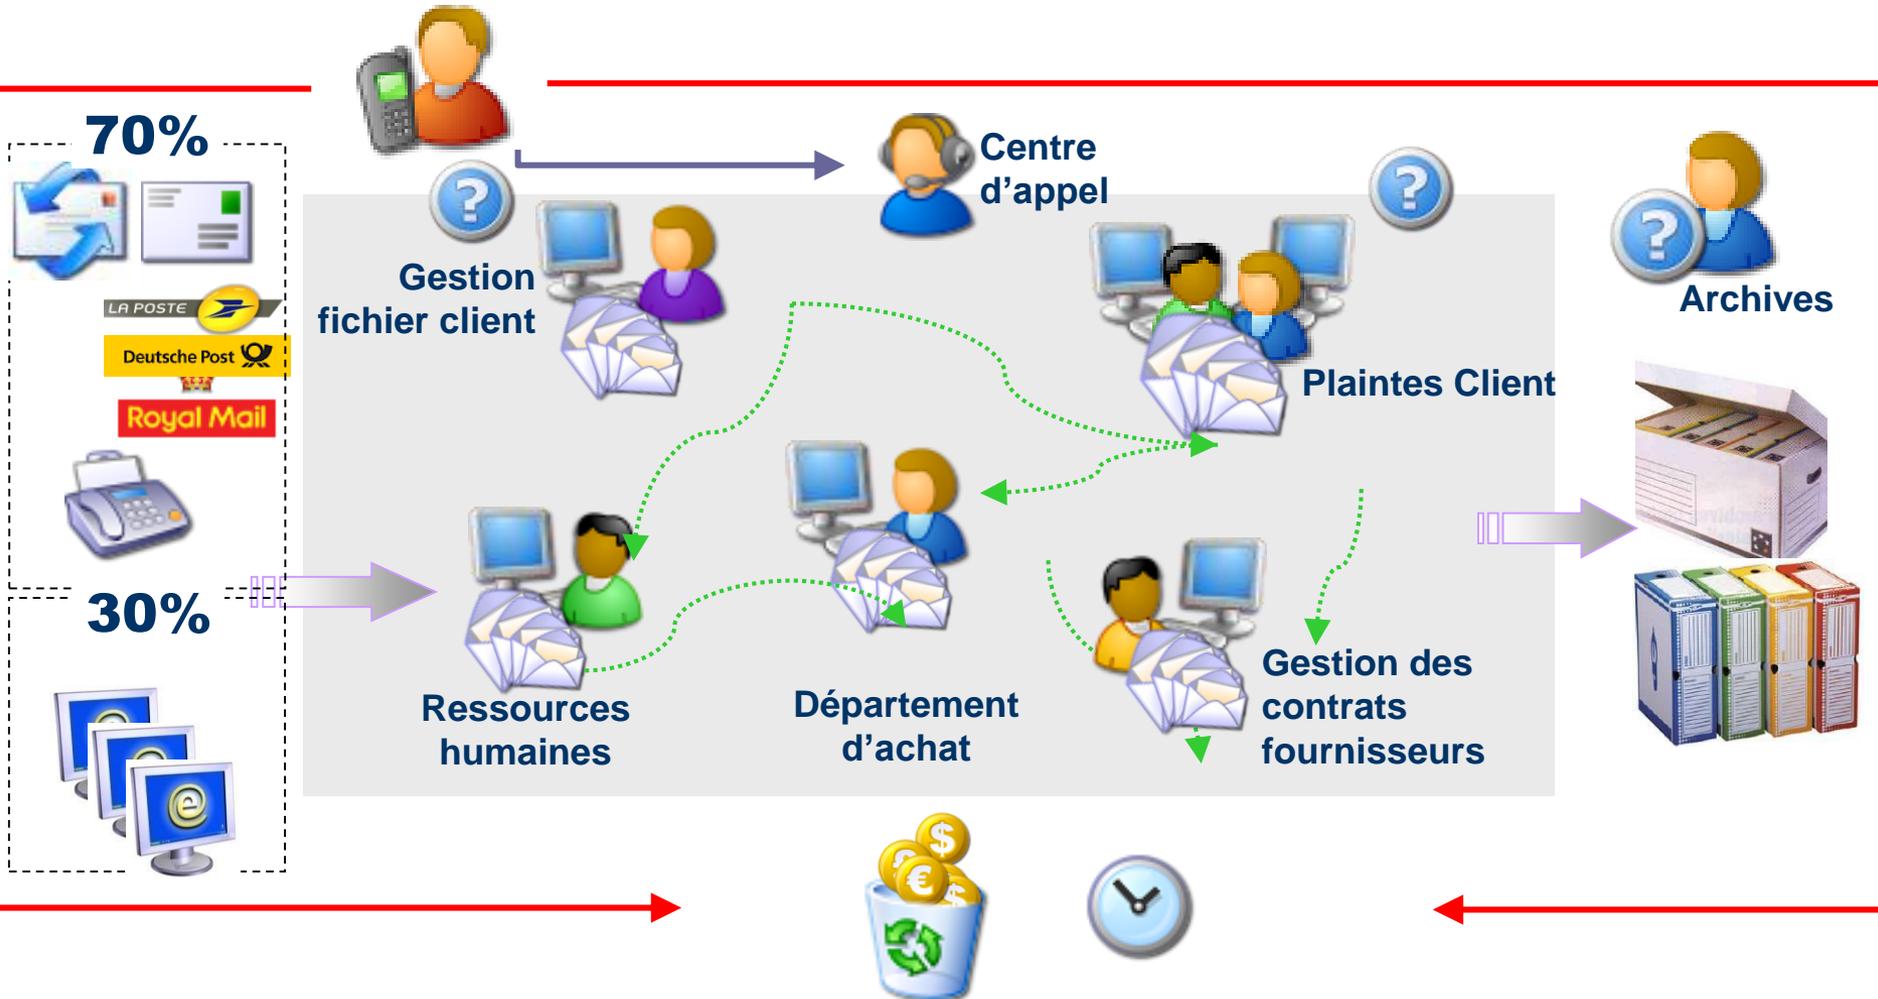
Acteur	Document	Produit	Traitement
Readsoft	Facture	«DOCUMENTS for Invoice»	Capture jusqu'à transformation
Captiva	Facture	« InputAccel for Invoices »	Tr. Automatique de facture – extraction d'information
Kofax	Document administratif	«Xtrata pro»	Classification document - extraction de données
BancTec	Chèque, remise, titre...	«eFIRST Clearing»	~ 5 milliards de chèques traités en France chaque année, 50% avec BancTec
IRIS	Courrier	«DocuTec»	Rétroconversion, Indexation
A2IA	Chèque	«CheckReader»	Lecture automatique de champs imprimés et manuscrits

- **Plusieurs applications administratives**
 - Dématérialisation des salles courriers : "Digital mailroom"
 - ➔ Traitement des flux entrants
 - Traitement automatique des moyens de paiement
 - ➔ Reconnaissance de montants : chèques, titres, traites...
 - Traitement de factures
 - ➔ Extraction d'identifiants
 - Gestion électronique de documents (contenus)
 - ➔ Circulation, diffusion, traçabilité, sécurisation, etc.

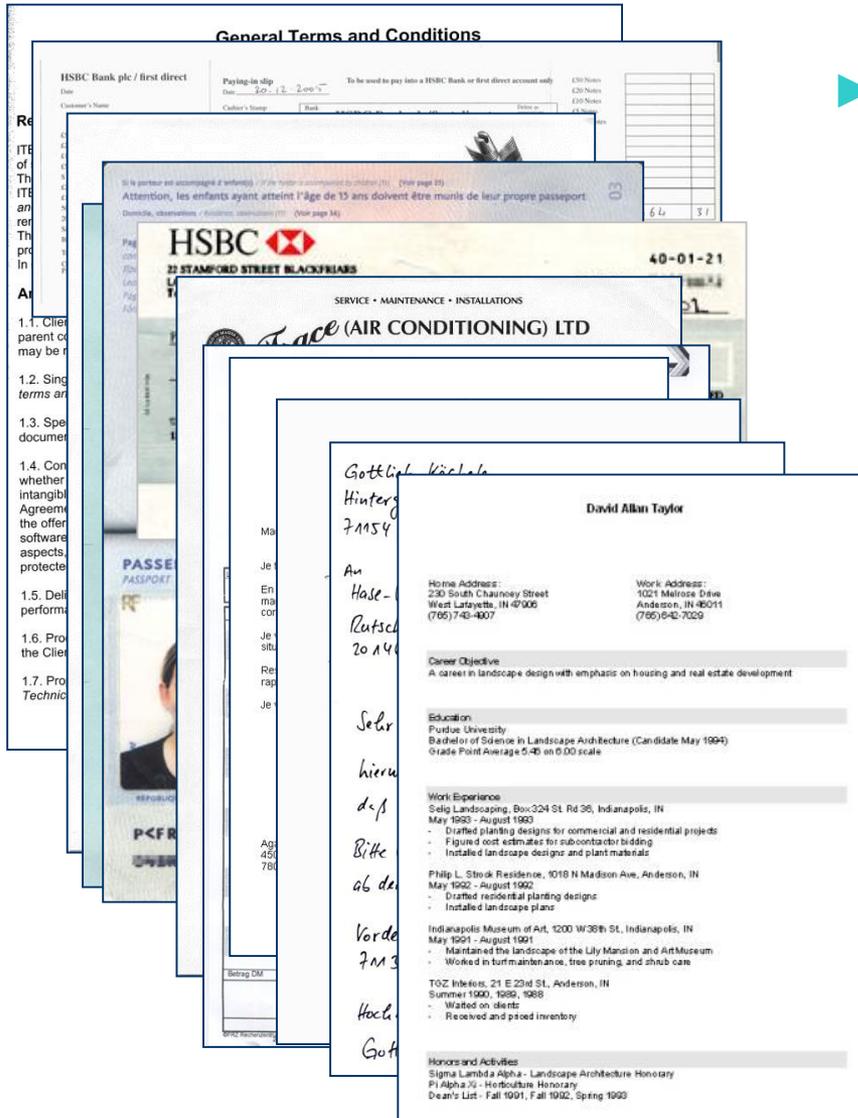
Problème du courrier

Le courrier met en interaction tous les départements de l'entreprise ...
Le client envoie une commande, celle-ci fait un circuit...

La commande peut arriver par téléphone ou en complément...



Traitement du courrier : un processus difficile



▶ Le courrier n'est jamais le même, le format change ... Ceci a une influence sur le process

▶ Il faut disposer d'une infrastructure d'exception et d'outils performants ...

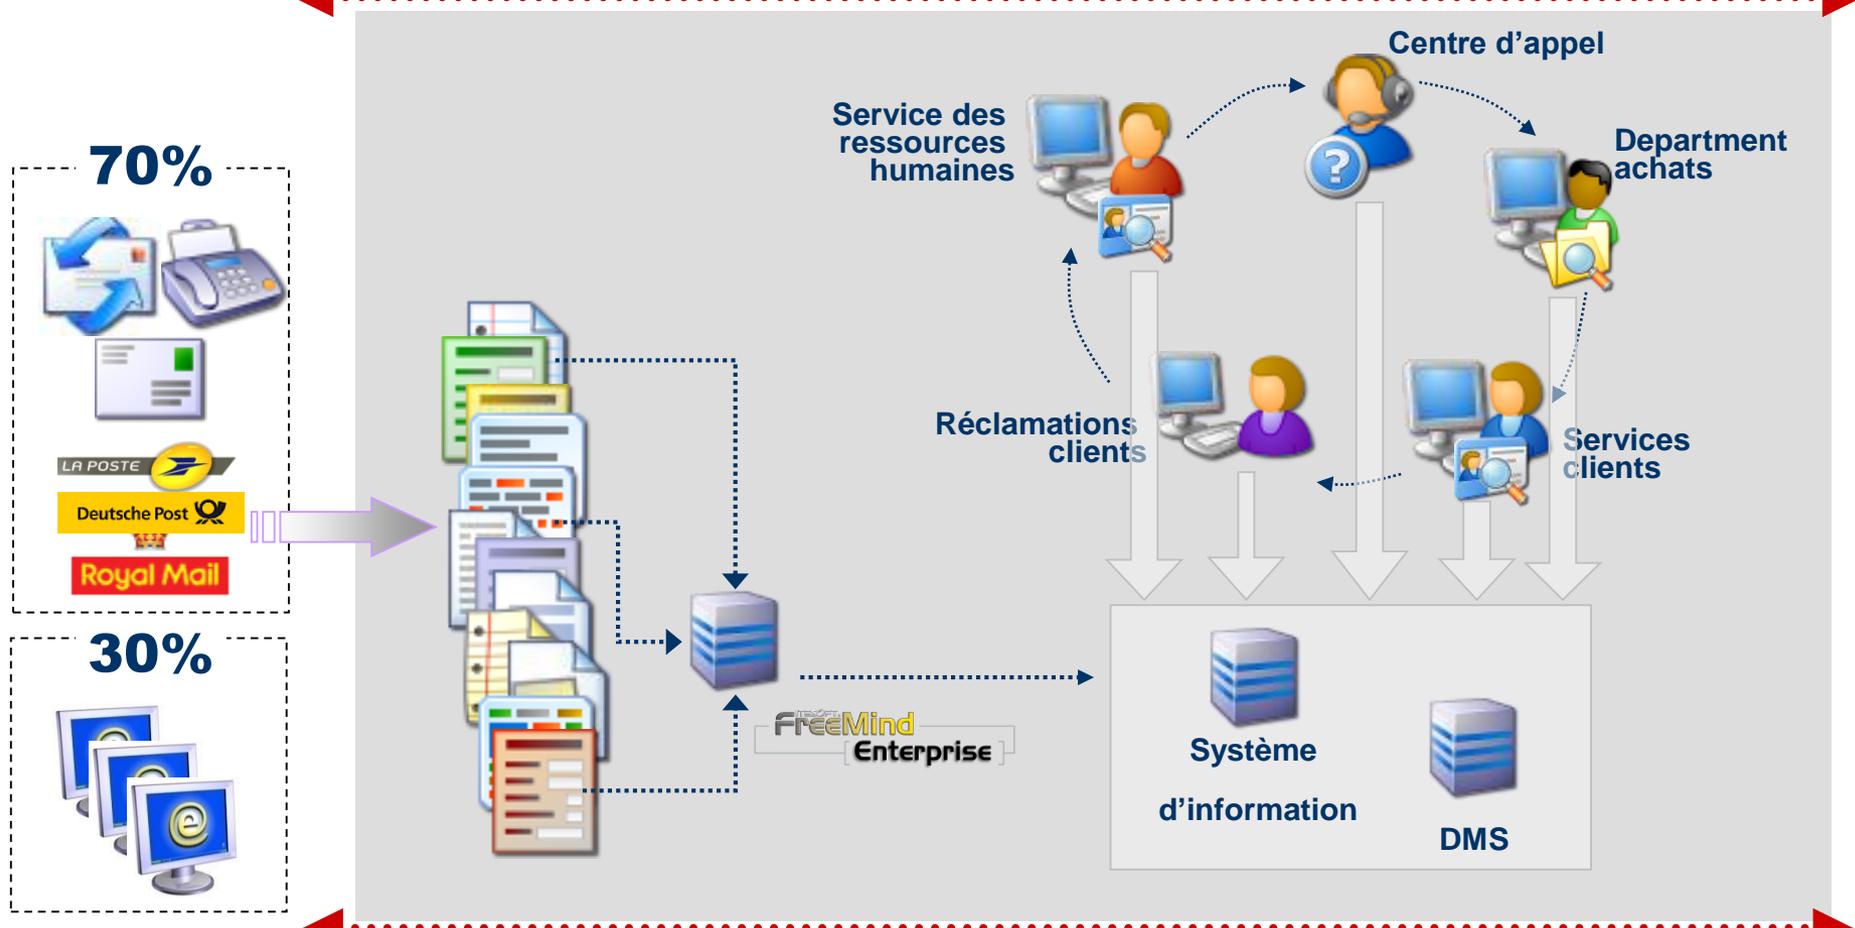
▶ L'efficacité des services dépend de la rapidité de la distribution du courrier

▶ La distribution sous forme papier n'est pas efficace, la traçabilité des documents est difficile

Le traitement électronique du courrier :

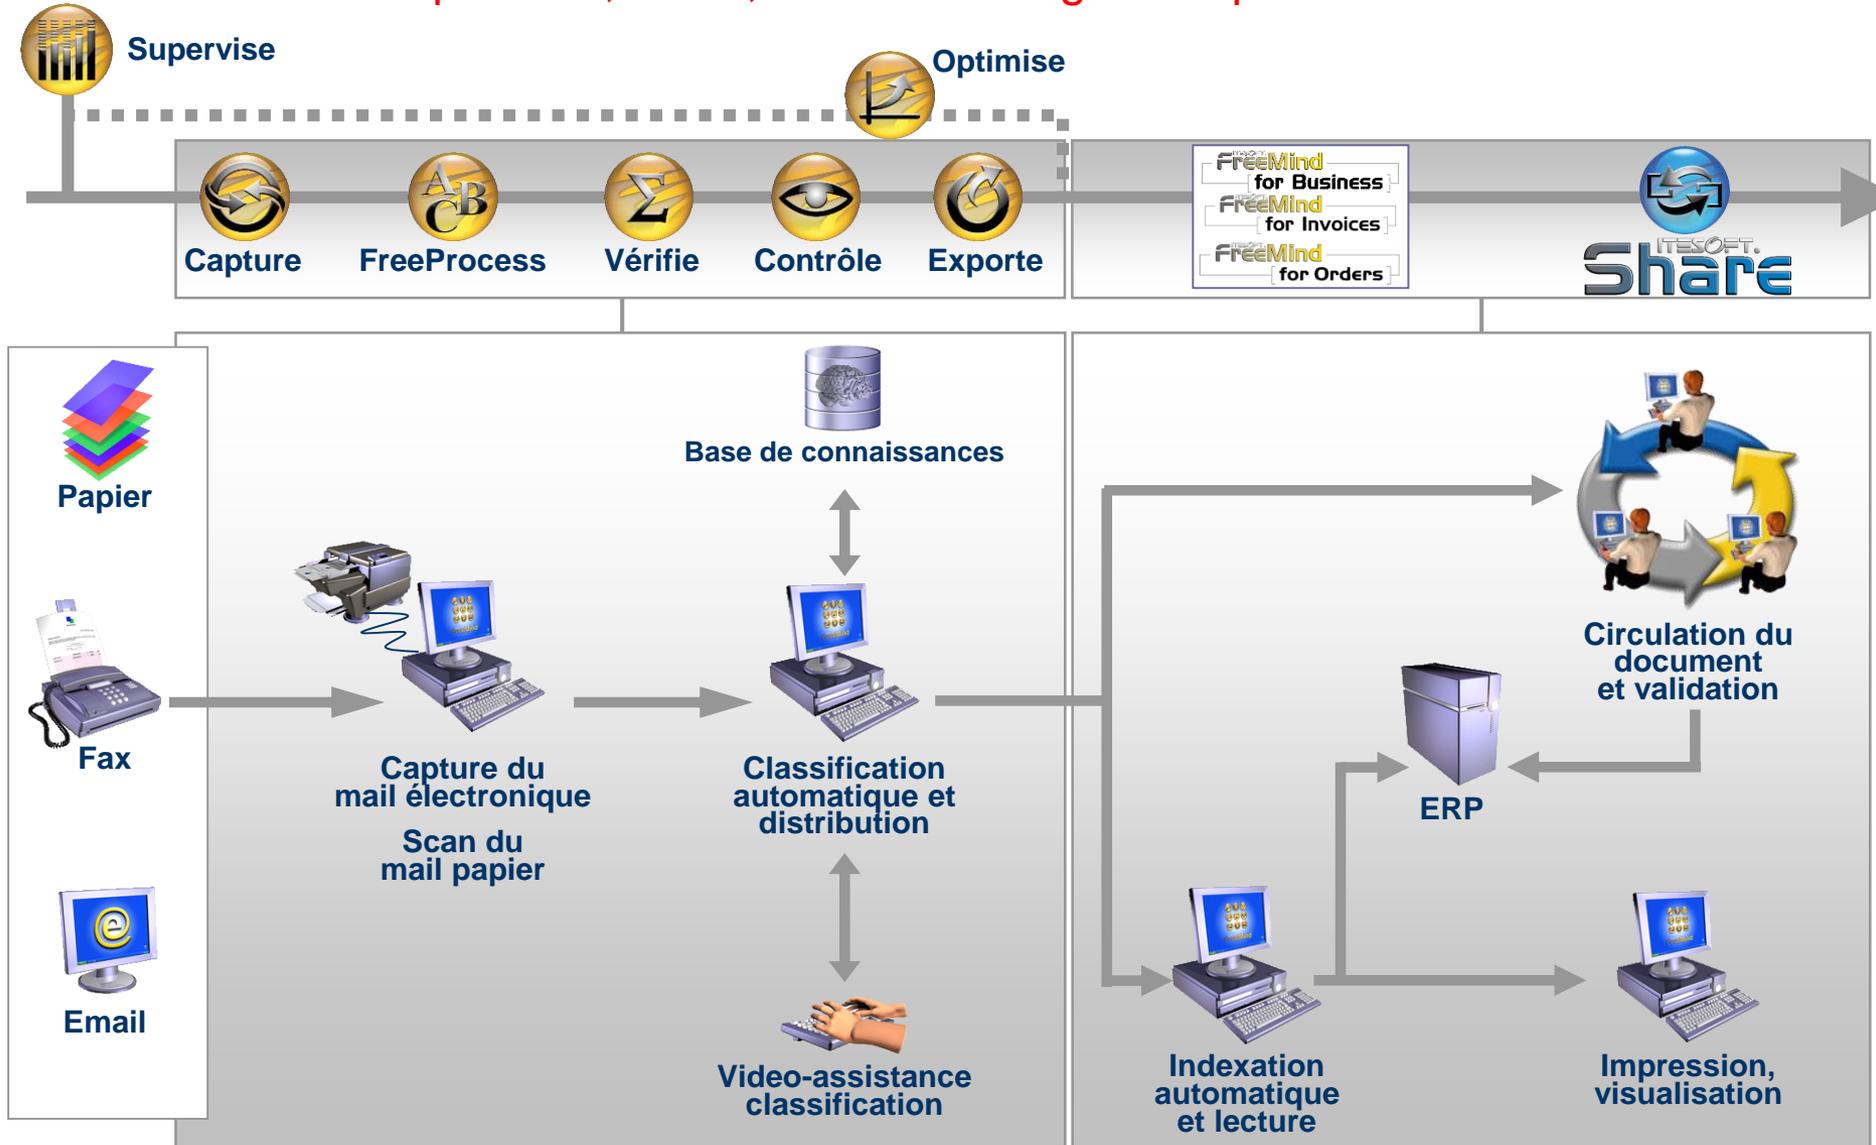
permet au système de l'insérer correctement dans la boucle

Plus clair pour sa distribution entre les services : coût, traçabilité



Les infos sont dans l'IS, le DMS les donne aux process : rapidité

Le courrier est analysé en utilisant les connaissances de l'entreprise : elle essaie de le classer automatiquement, sinon, un vidéocodage est opéré



Traitement du texte : 2 phases :

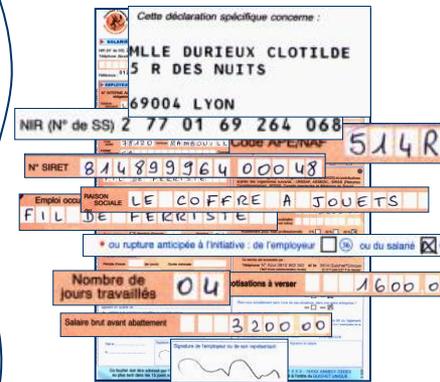
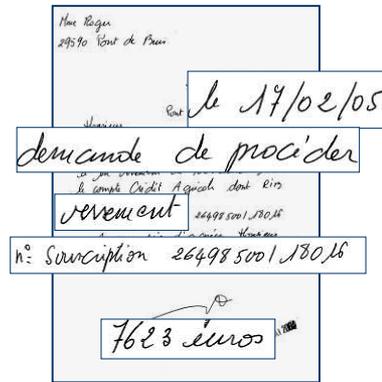
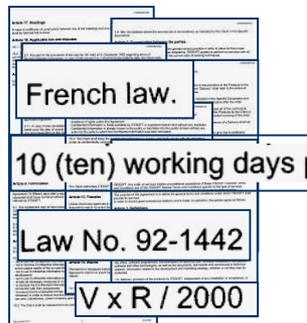
>>>

Indexation pour repérer

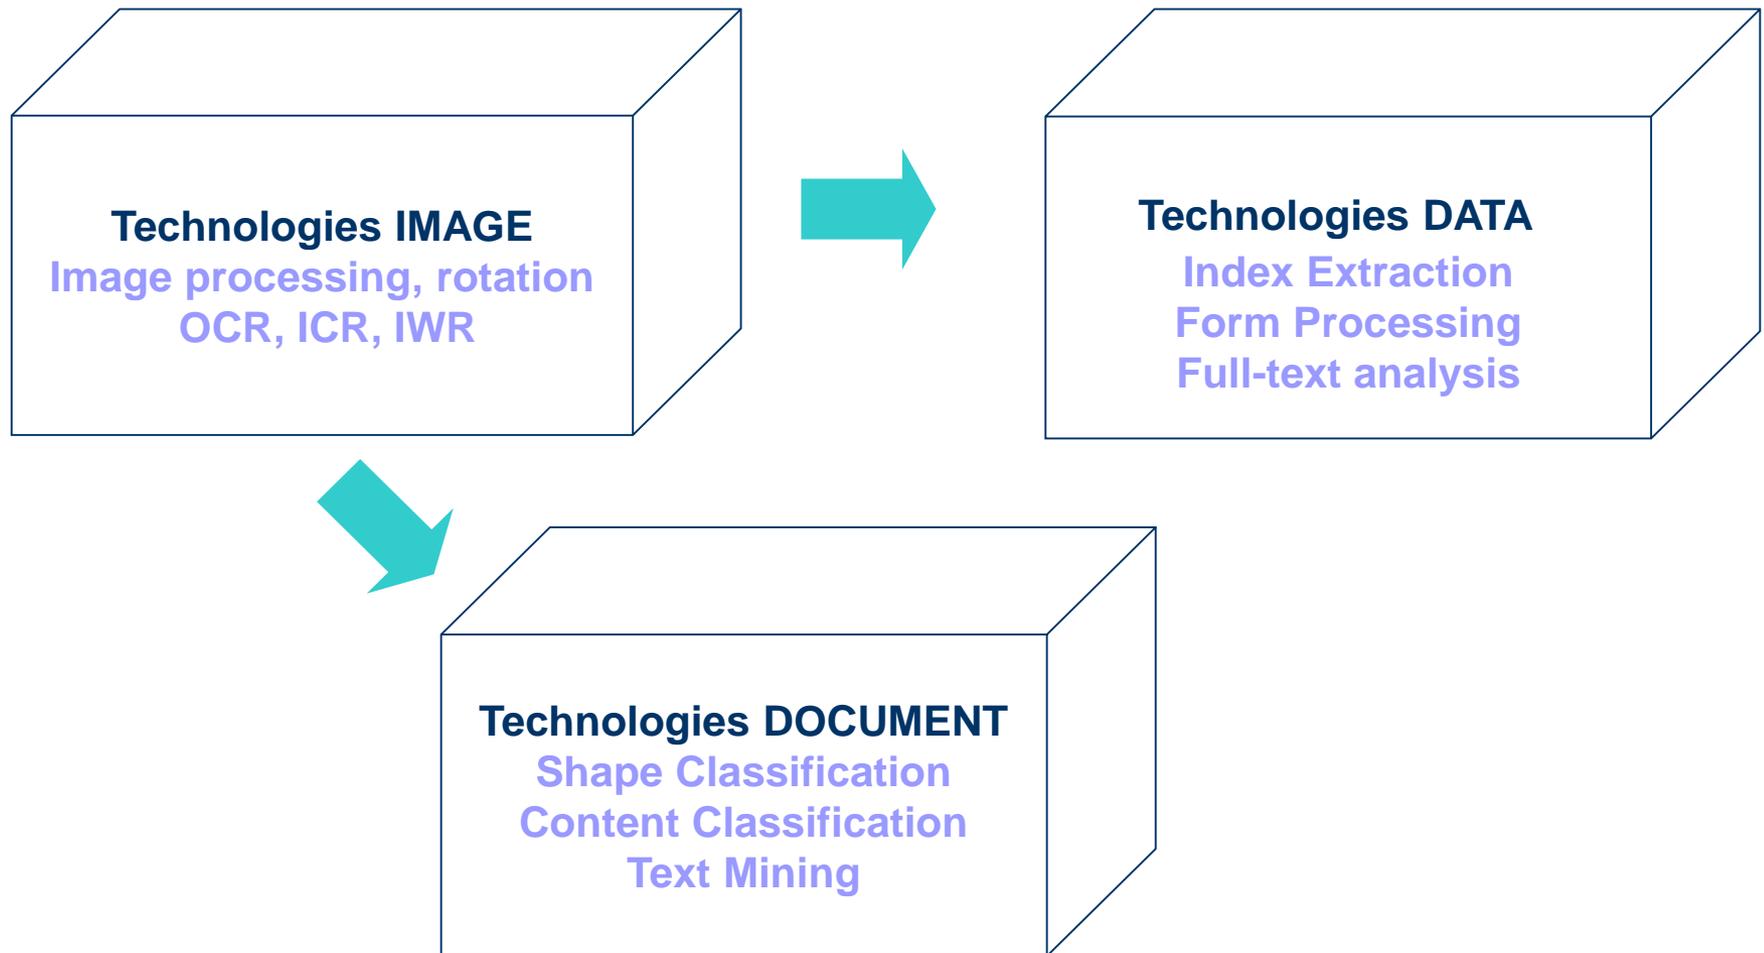
>>>

Lecture ciblée

>>>



Les technologies utilisées



Combinaison de techniques

Autorotation

I W R

I C R

Autodespeckle

O C R

PCM - impression du BCR Page 1 sur 1

 **le programme changer de mobile**

Exemplaire à retourner impérativement,
accompagné de :

N° client	N° facture
46 817 3	744 1414

- la copie de la facture d'achat du nouveau téléphone mobile,
- la carte SIM du coffret, si le nouveau mobile vendu est un coffret,
- la copie de la pièce d'identité du client.

Pour les entreprises bénéficiant d'un abonnement (hors Orange business solution), joindre :

- un pouvoir sur lequel figure le cachet commercial de l'entreprise et son numéro SIRET,
- la copie de la pièce d'identité de la personne mandatée.

Adresse de réexpédition : Orange France - le programme changer de mobile - 16 boulevard Gambetta - BP 272 - 02208 SOISSONS

Partie point de vente

Date : 25/05/2004

Nom du point de vente : VITTEL

Marque et modèle du téléphone choisi : Samsung S300m.

N° IMEI (figurant sur le téléphone) : 10196006481315

Prix du téléphone avant remise : 219.00 EUR TTC

Montant de la remise : 8.93 EUR TTC

Prix payé en point de vente : 210.07 EUR TTC

Cachet de l'agence
FRANCE TELECOM
Agence Commerciale de VITTEL
277, Avenue Maréchal Joffre
88900 VITTEL

Partie client

N° de téléphone mobile : 06.89.56.69.h7

Nom et prénom du client : *M. Marie Naïfe*

J'accepte de me réengager pour une durée minimale de 24 mois sur mon abonnement, à compter de la date de signature du présent document en contre partie de l'offre de renouvellement de mon téléphone. Les autres conditions contractuelles demeurent quant à elles inchangées.

J'ai bien noté que cette offre est réservée aux abonnés (hors Orange business solution) ayant au moins 500 points*, et à jour dans leurs paiements au titre de l'abonnement. Cette offre annule toute demande de résiliation antérieure.

*Certifie au l'honneur de sol de enue
appel le lundi 24 mai 2004 à 18h.*

*Sauf en cas de perte ou de vol confirmé par une déclaration auprès des services de police

Si vous avez choisi un téléphone contenu dans les coffrets Orange, contactez votre service clients dont le numéro figure en haut de vos factures d'abonnement pour le SAV. Les informations demandées aux abonnés lors de leur commande et contenues dans les fichiers d'Orange France ne sont transmises qu'aux personnes physiques ou morales qui sont expressément habilitées à les connaître. Tout abonné peut demander à Orange France la communication des informations le concernant et les faire rectifier le cas échéant, conformément à la loi n° 78-17 du 6 janvier 1978 sur l'informatique, les fichiers et les libertés.

FID PCP 0503

Orange France, SA au capital de 2 096 517 960 E - 428 706 097 RCS Nanterre - 41-45 boulevard Romani Roland - 92120 Montrouge

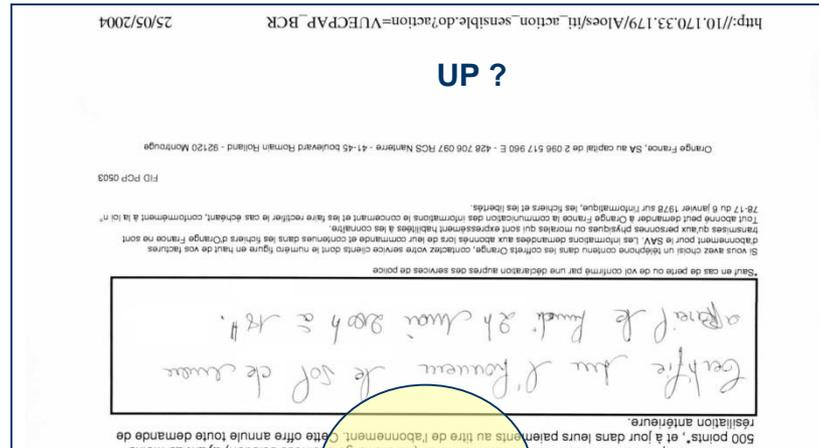
http://10.170.33.179/Aloes/iti_action_sensible.do?action=VUECPAP_BCR 25/05/2004

Auto-rotation :

Par l'orientation des lignes ou l'emplacement des hampes et jambages

Par l'orientation des lignes

Par l'emplacement des hampes et jambages

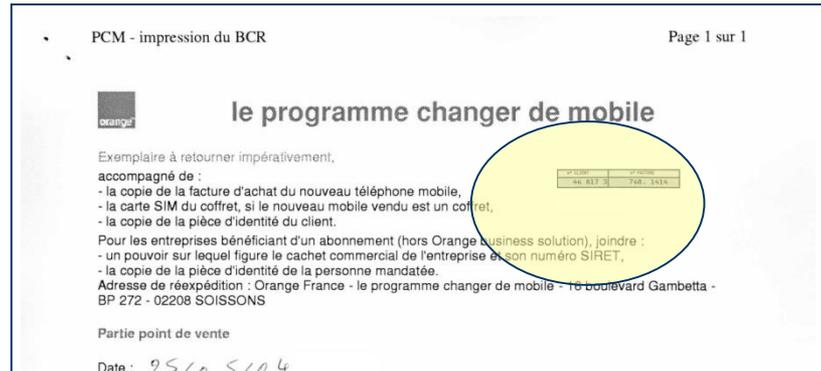


Portrait

Down ?

Autodespeckle

Localise les zones texturées et enlève les points : technique run length (transitions)



n° CLIENT	n° FACTURE
46 817 3	768. 1414

e,
coffret,

ange business solution), joindre :
entreprise et son numéro SIRET,

OCR

Différence entre OCR et ICR :

ICR

Permet de localiser le mot "date", mais ne peut pas lire le reste

Lit la date mais se trompe sans contexte : 1 et / sont proches, la connaissance de "date" lui permet de corriger

PCM - impression du BCR

Page 1 sur 1

le programme changer de mobile

Exemplaire à retourner impérativement, accompagné de :

- la copie de la facture d'achat du nouveau téléphone mobile,
- la carte SIM du coffret, si le nouveau mobile vendu est un coffret,
- la copie de la pièce d'identité du client.

Pour les entreprises bénéficiant d'un abonnement (hors Orange business solution), joindre :

- un pouvoir sur lequel figure le cachet commercial de l'entreprise et son numéro SIRET,
- la copie de la pièce d'identité de la personne mandatée.

Adresse de réexpédition : Orange France - le programme changer de mobile - 16 boulevard Gambetta - BP 272 - 02208 SOISSONS

Partie point de vente

Date : 25/05/04

Nom du point de vente : VITTEL

Marque et modèle du téléphone choisi : Samsung S300m.

N° IMEI (figurant sur le téléphone) : 10196006481315

Prix du téléphone avant remise : 219.00 EUR TTC

Montant de la remise : 8.93 EUR TTC

Prix payé en point de vente : 210.07 EUR TTC

Cachet de l'agence
FRANCE TELECOM
Agence Commerciale de VITTEL
277, Avenue Maréchal Joffre
VITTEL

25 / 05 / 04

Date : 25/05/04

25105104

*Sauf en cas de perte ou de vol confirmé par une déclaration auprès des services de police

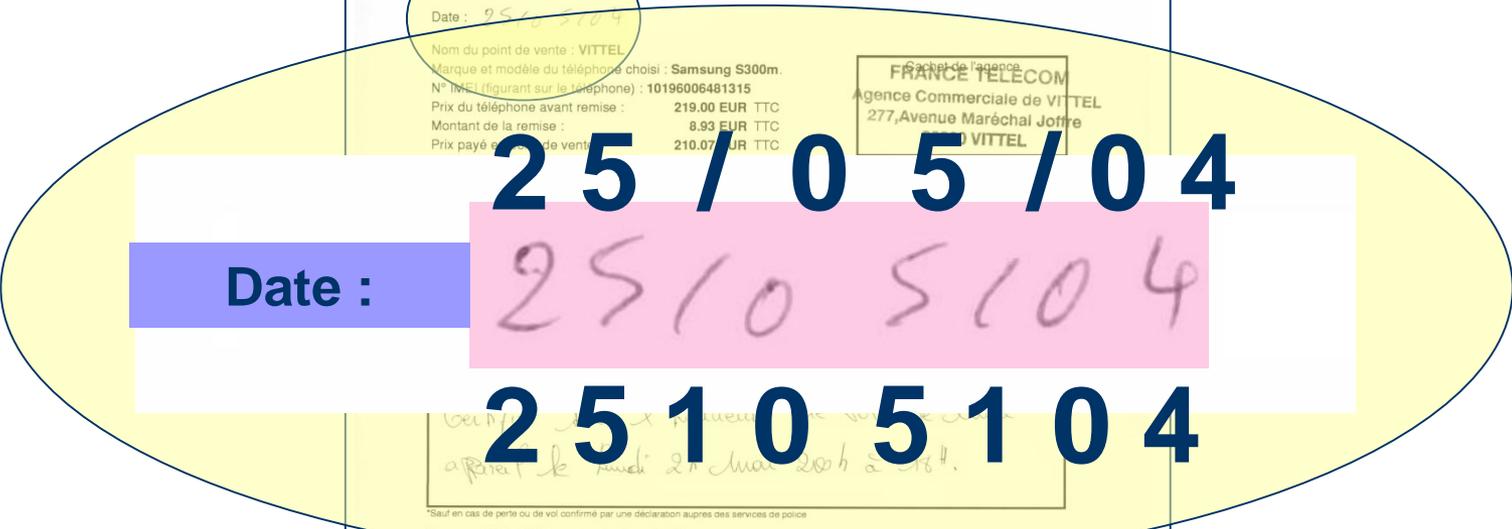
Si vous avez choisi un téléphone contenu dans les coffrets Orange, contactez votre service clients dont le numéro figure en haut de vos factures pour le SAV. Les informations demandées aux abonnés lors de leur commande et contenues dans les fichiers d'Orange France ne sont transmises qu'en cas de chèques ou monnaies qui sont expressément habilités à les connaître.

Tout abonné peut demander à Orange France de supprimer ses données personnelles et de supprimer le cas échéant, conformément à la loi n° 78-17 du 6 janvier 1978 sur l'informatique, les fichiers et les libertés.

FID PCP 0503

Orange France, SA au capital de 2 096 517 960 E - 428 706 097 RCS Nanterre - 41-45 boulevard Romani Rolland - 92120 Montrouge

http://10.170.33.179/Aloes/iti_action_sensible.do?action=VUECPAP_BCR 25/05/2004



I W R

Français ou anglais ? Caractères collés. Le ti ressemble au h ?

PCM - impression du BCR Page 1 sur 1

 **le programme changer de mobile**

Exemplaire à retourner impérativement,
accompagné de :

N° client	N° facture
44 817 3	744 1414

- la copie de la facture d'achat du nouveau téléphone mobile,
- la carte SIM du coffret, si le nouveau mobile vendu est un coffret,
- la copie de la pièce d'identité du client.

Pour les entreprises bénéficiant d'un abonnement (hors Orange business solution), joindre :

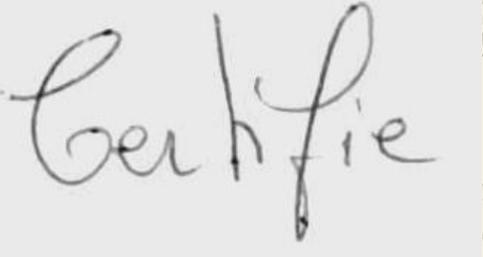
- un pouvoir sur lequel figure le cachet commercial de l'entreprise et son numéro SIRET,
- la copie de la pièce d'identité de la personne mandatée.

Adresse de réexpédition : Orange France - le programme changer de mobile - 16 boulevard Gambetta - BP 272 - 02208 SOISSONS

Partie point de vente

Date : 25/05/04

Point de vente : VITTEL



RECÉPTE
Copie de VITTEL
réception Joffe
VITTEL

Compte de la
téléphone.

au moins
demande de

En cas de perte ou de vol confirmé par une déclaration auprès des services de police

Si vous avez choisi un téléphone contenu dans les coffrets Orange, contactez votre service clients dont le numéro figure en haut de vos factures
pour le SAV. Les informations demandées aux abonnés lors de leur commande et contenues dans les fichiers d'Orange France ne sont
pas liées à ceux des personnes physiques ou morales qui sont expressément habilitées à les connaître.
Le client peut demander à Orange France la communication des informations le concernant et les faire rectifier le cas échéant, conformément à la loi n°
du 6 janvier 1978 sur l'informatique, les fichiers et les libertés.

FID PCP 0503

Orange France, SA au capital de 2 096 517 960 E - 428 706 097 RCS Nanterre - 41-45 boulevard Romain Rolland - 92120 Montrouge

Problèmes

● Segmentation de notes ?

● Pas de segmentation des

● Lien avec des dictionnaires

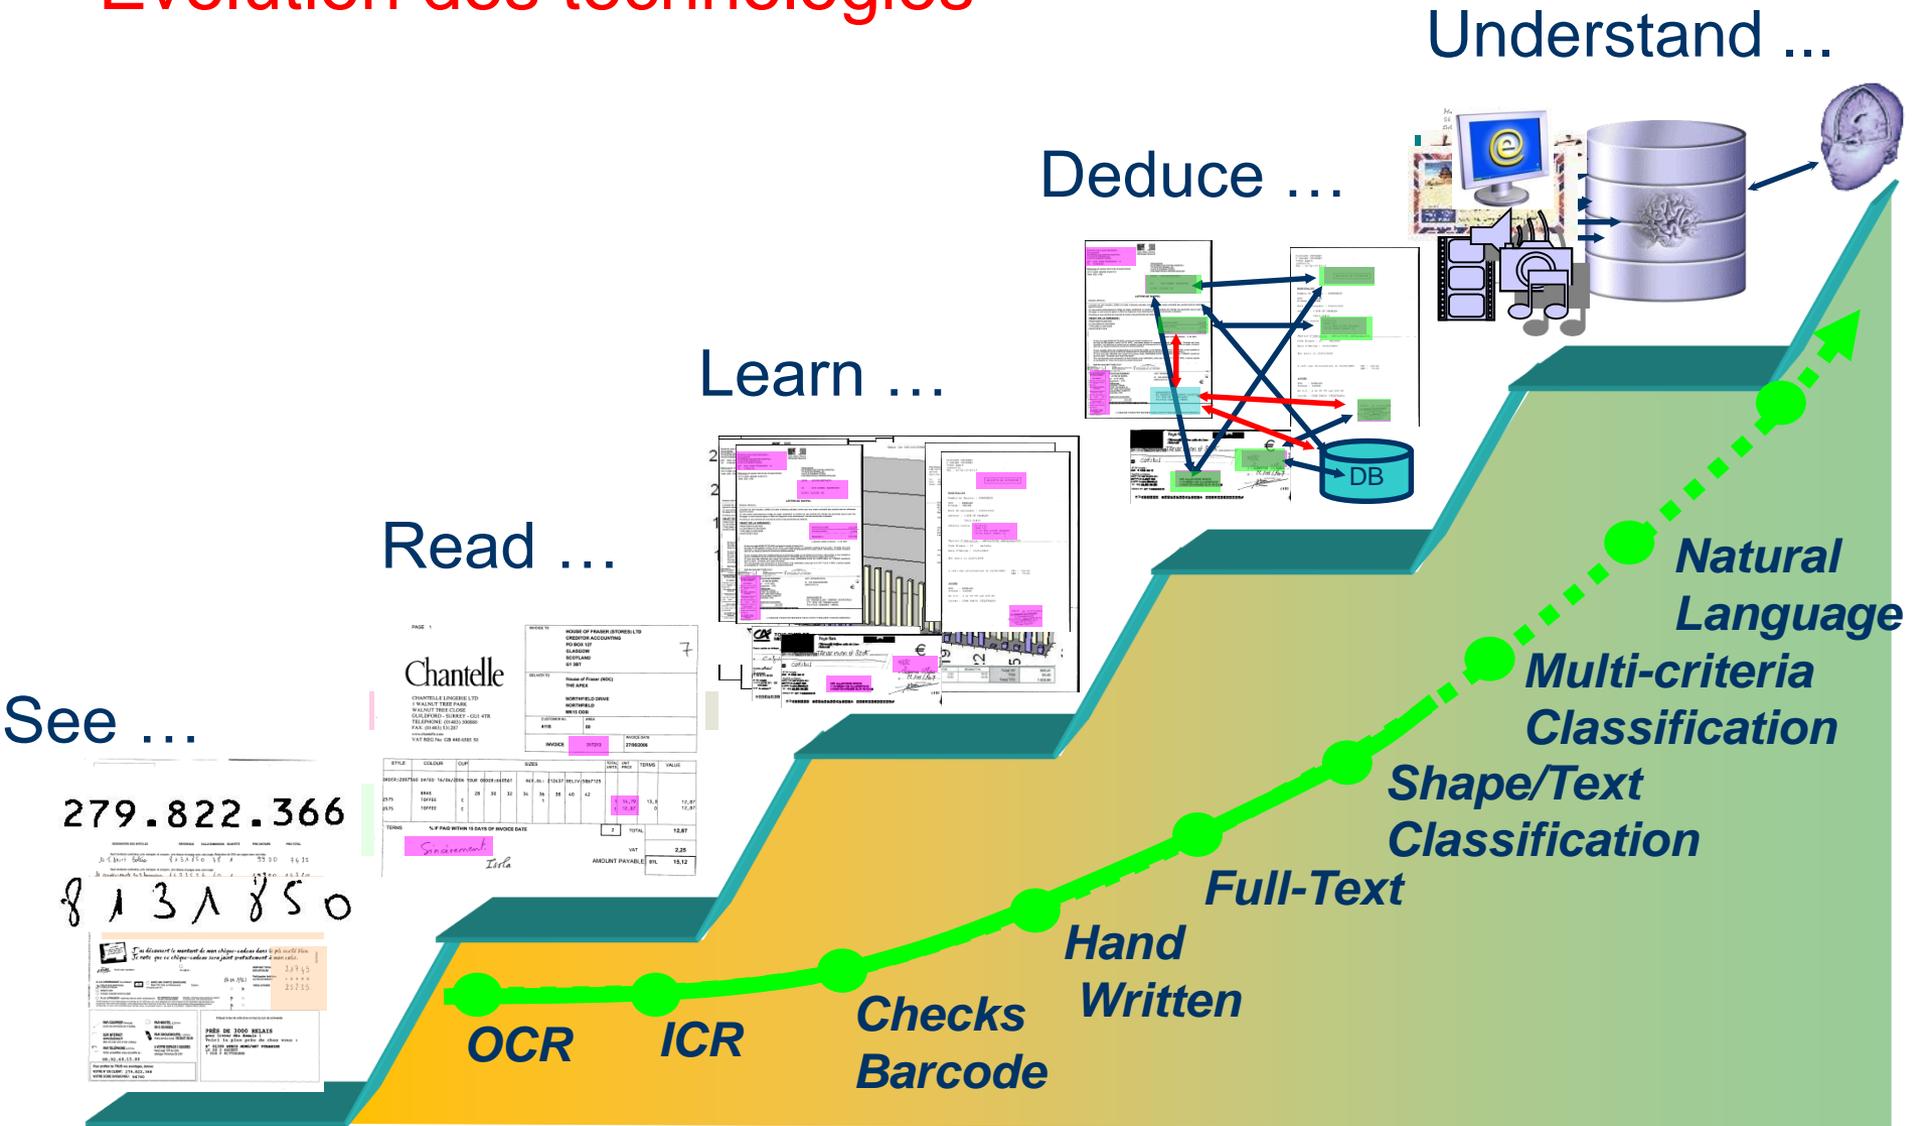
● Petit, moyen, large ?

● Fermé ou ouvert ?

● Moyen & Ouvert

Conclusion sur les formulaires

Évolution des technologies



Conclusion sur la READ

- 3 périodes
 - Un passé pessimiste
 - Rien ne fonctionnait
 - Les OCRs étaient voués à l'échec
 - Pas d'horizon pour le manuscrit
 - Un présent satisfaisant
 - Entrée dans le monde industriel
 - On peut faire de la masse rapidement
 - On a noué des liens avec le NLP, le Data Mining (ce n'est plus une thématique isolée, mais un élément d'un grand ensemble)
 - Un futur prometteur
 - Capable de répondre à beaucoup de défis dans des problématiques réelles : numérisation du patrimoine ancien
 - OCR : Élément essentiel des moteurs de recherche
 - Domaine de recherche ouvert...