




De quelles données avons-nous besoin?
Aspects techniques et pratiques

Khalid Choukri
 (ELRA/ELDA)
 De la part du consortium ELRC

ELRC--- Atelier France 2016/05/11 1




Quelles données ? Essentiellement des traductions

- L'approche prédominante est un paradigme « apprentissage » à partir des données
 - systèmes de Traduction Automatique apprennent à partir des données existantes
 - le focus pour ELRC: Les données linguistiques dans toutes les langues (UE / CEF)
- Les Ressources Linguistiques (RLs) sont produites à partir de:
 - Documents et autres données linguistiques
 - Diverses sources comme le web
- Votre concours est important (avec les données que vous avez ou dont vous connaissez les détenteurs)

ELRC--- Atelier France 2016/05/11 2



Que considère-t-on comme données pour la TA?



- Tout ce qui contient des « mots », préférences pour des « phrases », surtout des phrases exprimées en plusieurs langues, par exemple:
 - Rapports, documents,
 - Discours (transcriptions),
 - Contenus de pages web,
 - Brochures, etc.

- Sacs de « mots », « phrases », plusieurs sacs



ELRC--- Atelier France 2016/05/11

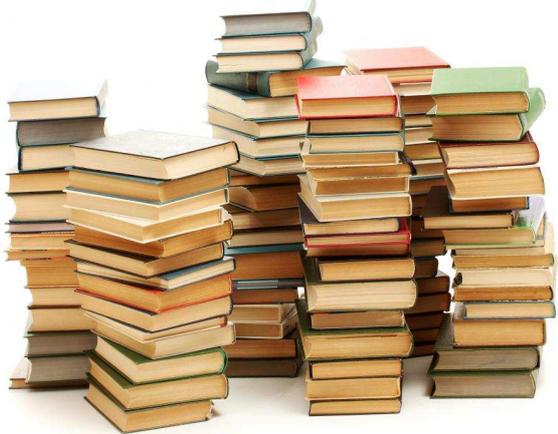
3



Que considère-t-on comme données pour la TA?







ELRC--- Atelier France 2016/05/11

4

European Language Resource Coordination
Connecting Europe Facility

Que considère-t-on comme données pour la TA?



Traductions « alignées »

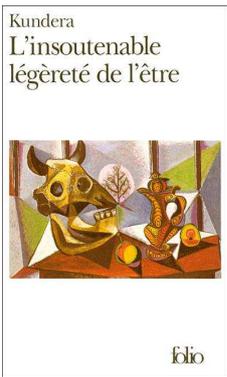
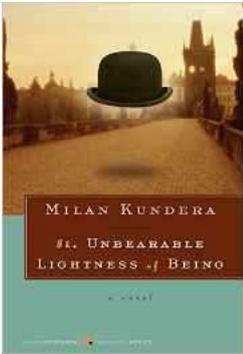
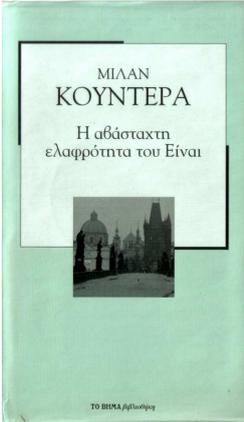


Anglais Français

ELRC--- Atelier France 2016/05/11 5

European Language Resource Coordination
Connecting Europe Facility

Exemple ... Illustrations

ELRC--- Atelier France 2016/05/11 6

European Language
Resource Coordination
Connecting Europe Facility

Traductions « alignées » Extraction d'unité



<p>The Vikings were Scandinavian seafarers who lived in the ninth, tenth, and the beginning of the eleventh century, which is known as the Viking era. The Vikings were heathens and did not become Christian until around the year 1000. Their own gods were called the Æsir, and offerings were made to them at the blot, a kind of religious sacrificial holiday.</p>	<p>Die Wikinger waren skandinavische Seefahrer, die im 9., 10. und Anfang des 11. Jahrhunderts lebten, auch bekannt als Wikinger-Epoche. Die Wikinger waren Heiden und wurden erst um das Jahr 1000 zu Christen. Ihre eigenen Götter nannten sie Æsir, denen sie an Blot, einen religiösen Opferfest, Gaben darbrachten. Vier dieser Götter waren Tyr (oder Týr), Óðin (oder Odinn), Thor und Frigg, nach denen drei Wochentage benannt sind: Dienstag, Donnerstag und Freitag. Auch die Monate hatten ihre eigenen Namen, aber heutzutage benutzen die Skandinavier die römischen Namen für die Monate: Januar, Februar, März etc.</p>
<p>Four of these gods were Tyr (or Týr), Óðin (or Odinn), Thor, and Frigg, who have given their names to four of the days of the week: Tuesday, Wednesday, Thursday and Friday. The months had their own names as well, but now the Scandinavians use the Roman names for the months: January, February, March etc.</p>	<p>Viele Wikinger segelten in ihren Langschiffen oder Dreikar hinaus in die Welt, bis nach Amerika und Konstantinopel. Ihre Schiffe hatten relativ flache Böden, so daß sie sich damit auch nahe der Küste und in seichten Flüssen bewegen konnten.</p>
<p>Many Vikings sailed out into the world in their long-ships, or drekkar, as far as America and Constantinople. Their ships had relatively flat bottoms, so that they could sail near the coast and up shallow rivers. In the West they met Indians, and in the East they met Arabs. But in the Atlantic they navigated by the stars, and in the year 1000 Leif Eriksson set foot on American soil, and forty years later, Ingvar the Wide-Travelled reached the southern shore of the Caspian sea. In this way, local kings had contact with lands which lay far away. In large areas of England Danish law held sway; that area was therefore called the Danelaw. In Constantinople, the emperor had a feared bodyguard composed of Vikings. Because of their distinctive axes, they were called "the Axe-bearing Barbarians."</p>	<p>Im Westen begegneten sie Indianern und im Osten Arabern. Auf den Atlantik navigierten sie mit Hilfe der Sterne und im Jahr 1000 setzte Leif Eriksson seinen Fuß auf amerikanischen Boden, und vierzig Jahre später erreichte Ingvar, 'der Weitgereiste', die Südküste des Kaspischen Meeres. Auf diese Weise kamen einheimische Könige in Kontakt mit Ländern, die weit entfernt waren.</p>
<p>At home the Vikings lived relatively simply. They sowed rye in the fields and kept cows, which gave milk, pigs, for pork, and sheep, for wool. Those who lived along the coasts caught fish. They often lived in long-houses, which could house several families. Three or four brothers, for example, could live with their families together in one big house.</p>	<p>In weiten Teilen Englands herrschte dänisches Gesetz. Diese Gebiete wurden deshalb Danelaw genannt. In Konstantinopel hielt sich der Herrscher eine gefürchtete Wikingergarde. Wegen ihrer typischen Streitäxte wurden sie die Äxt-tragenden Barbaren genannt.</p> <p>[]</p> <p>Zu Hause lebten die Wikinger recht einfach. Auf den Feldern kultivierten sie Roggen und sie hielten Kühe, die sie mit Milch versorgten. Schweine hielten sie wegen des Fleisches und Schafe für Wolle. Jene, die an der Küste lebten, fingen Fisch. Die Wikinger wohnten gewöhnlich in Langhäusern, die mehrere Familien beherbergen konnten. Drei oder vier Brüder konnten, zum Beispiel, zusammen mit ihren Familien in einem einzigen großen Haus leben.</p>

ELRC--- Atelier France 2016/05/11 7

European Language
Resource Coordination
Connecting Europe Facility

Ensemble de textes comparables en 2 ...3 ... langues



English	Greek	Spanish
<p>Telecommunication occurs when the exchange of information between two or more entities (communication) includes the use of technology.</p> <p>Communication technology uses channels to transmit information (as electrical signals), either over a physical medium (such as signal cables), or in the form of electromagnetic waves.</p> <p>The word is often used in its plural form, telecommunications, because it involves many different technologies.</p>	<p>Με τον γενικό όρο τηλεπικοινωνίες, (telecommunications), χαρακτηρίζεται η κάθε μορφής ενσύρματη ή ασύρματη, ηλεκτρομαγνητική, ηλεκτρική, κ.λπ., ακουστική και οπτική επικοινωνία που πραγματοποιείται ανεξαρτήτως απόστασης.</p> <p>Στους σύγχρονους καιρούς, αυτή η διαδικασία σχεδόν πάντα περιλαμβάνει την απόστολή ηλεκτρομαγνητικών κυμάτων ή ηλεκτρικών σημάτων από κατάλληλες ηλεκτρονικές συσκευές, όπως το τηλέφωνο ή ο ασύρματος, αλλά παλαιότερα περιελάμβανε τη χρήση ακουστικών σημάτων, όπως τυμπάνων, ή οπτικών, όπως ο σηματοφόρος καπνός ή η λάμψη της φωτιάς.</p>	<p>Una telecomunicación es toda transmisión y recepción de señales de cualquier naturaleza, típicamente electromagnéticas, que contengan signos, sonidos, imágenes o, en definitiva, cualquier tipo de información que se desee comunicar a cierta distancia.</p> <p>Por metonimia, también se denomina telecomunicación (o telecomunicaciones, indistintamente) a la disciplina que estudia, diseña, desarrolla y explota aquellos sistemas que permiten dichas comunicaciones; de forma análoga, la ingeniería de telecomunicaciones resuelve los problemas técnicos asociados a esta disciplina.</p>

Source: Premières phrases de l'article « Télécommunications » dans le Wikipédia anglais, grec et espagnol.
Le texte espagnol est légèrement différent mais il ne s'agit jamais de traductions de la même source !!

ELRC--- Atelier France 2016/05/11 8

European Language Resource Coordination
Connecting Europe Facility

Dictionnaires / Bdd terminologiques /Ontologies



previous level in time or space.

ID	FR	ES	EL
6905	abandon scolaire	abandono escolar	διακοπή της σχολικής φοίτησης
920	abats	despojo	παραπροϊόντα σφαγίων
1857	abattage d'animaux	sacrificio de animales	σφαγή ζώων
6621	abrogation	derogación	κατάργηση
5075	Abruzzes	Abruzos	Αβρουζία
5339	absentéisme	absentismo	συστηματική απουσία από την εργασία
5984	abstentionnisme	abstencionismo	αποχή
2	abus de confiance	abuso de confianza	απιστία
2	abus de droit	abuso de derecho	κατάχρηση δικαιώματος
2	abus de pouvoir	abuso de poder	κατάχρηση εξουσίας
2	accès à l'éducation	acceso a la educación	πρόσβαση στην εκπαίδευση
2	accès à l'emploi	acceso al empleo	πρόσβαση στην αγορά εργασίας




ELRC--- Atelier Franc

9

European Language Resource Coordination
Connecting Europe Facility

Monde numérique / digital

ELRC--- Atelier France 2016/05/11

10

European Language Resource Coordination
Connecting Europe Facility

Quel est le bon format ? Texte numérique & manipulable

ELRC--- Atelier France 2016/05/11

11

European Language Resource Coordination
Connecting Europe Facility

La documentation des données (Meta-data)

Les éléments descriptifs (metadata)
du Dublin Core

1. Titre // Title
2. Créateur // Creator
3. Sujet // Subject
4. Description // Description
5. Éditeur // Publisher
6. Contributeur // Contributor
7. Date // Date
8. Type // Type
9. Format // Format
10. Identifiant // Identifier
11. Source // Source
12. Langue // Language
13. Relation // Relation
14. Couverture // Coverage
15. Droits // Rights

➤ On peut définir ce qui est essentiel au cas par cas

- Sources de données (fiabilité, qualité, etc.)
- Domaines spécifiques
- Langues
- Droits (si données non publiques)

ELRC--- Atelier France 2016/05/11

12

Comment produit-on les Ressources Linguistiques à partir de « données »



- Des données brutes (« raw data ») comme des pages html avec tableaux, images, etc.) peuvent être converties
 - Découvrir et identifier les sources (e.g.: URL)
 - Clarifier les aspects juridiques (propriété intellectuelle, licence)
 - Obtenir les données (réception/envoi, téléchargement « crawling »)
 - Nettoyer les données (par exemple détecter et supprimer les « boilerplate », « modèles », des images, des balises html, etc., convertir le format)
 - Documenter les données (à la « Dublin Core » ou selon notre meta-data)
 - Aligner les traductions lorsque identifiées et segmentation en « unités » de traduction
 - Calculer un score de fiabilité de l'alignement
 - Partager
- ➔ Exemple de moissonnage de données

Gestion de données bilingues Exemple (1/4)



Documents Word provenant de <http://www.diplomatie.gouv.fr/fr/photos-videos-publications/publications/enjeux-planetaires-cooperation/rapports/article/rapports-du-groupe-pilote-Financements-innovants-pour-l'agriculture,la-securite-alimentaire-et-la-nutrition,Ministere-des-Affaires-etrangeres-et-du-Dveloppement-international>



Anglais



Français





Gestion de données bilingues Exemple (2/4)



EXECUTIVE
SUMMARY

RÉSUMÉ



→ This report is the result of a collective work carried out by the high-level expert Committee and a writing team commissioned by the Task Force on Innovative Financing for agriculture, food security and nutrition created by the Leading Group on Innovative Financing for Development at its 9th plenary session in Mali (Bamako) in June 2011.

The report includes an analysis of the need for innovating financing dedicated to the agricultural, food security and nutrition sector, a critical review of existing and possible mechanisms and a proposed selection of avenues for the development of such mechanisms on the basis of the

→ Le présent rapport résulte d'un travail collectif mené par le Comité d'experts de haut niveau et une équipe de rédacteurs désignés à cette fin par le groupe de travail sur les financements innovants pour l'agriculture, la sécurité alimentaire et la nutrition. Ce groupe de travail a été créé par le Groupe pilote sur les financements innovants pour le développement lors de sa 9e session plénière, qui s'est tenue au Mali (Bamako) en juin 2011.

Le présent rapport comporte une analyse des raisons pour lesquelles des financements innovants dédiés à l'agriculture, à la sécurité alimentaire et à la nutrition sont nécessaires, propose un examen critique des mécanismes existants et possibles, et

ELRC--- Atelier France 2016/05/11
15



Gestion de données bilingues Exemple (3/4)



La version anglaise – Données Brutes

La version française – Données Brutes

<p>Executive Summary</p> <p>This report is the result of a collective work carried out by the high-level expert Committee and a writing team commissioned by the Task Force on Innovative Financing for agriculture, food security and nutrition created by the Leading Group on Innovative Financing for Development at its 9th plenary session in Mali (Bamako) in June 2011.</p> <p>The report includes an analysis of the need for innovating financing dedicated to the agricultural, food security and nutrition sector, a critical review of existing and possible mechanisms and a proposed selection of avenues for the development of such mechanisms on the basis of the expertise of a high-level Committee of experts, literature review, meetings with relevant professional actors and an on-line consultation on the Global Forum on food security and nutrition (FSN Forum).</p> <p>The setting up of the Task Force on Innovative Financing for agriculture, food security and nutrition responds to current and future crucial challenges faced by the international community</p> <p>[...]</p>	<p>Résumé</p> <p>Le présent rapport résulte d'un travail collectif mené par le Comité d'experts de haut niveau et une équipe de rédacteurs désignés à cette fin par le groupe de travail sur les financements innovants pour l'agriculture, la sécurité alimentaire et la nutrition. Ce groupe de travail a été créé par le Groupe pilote sur les financements innovants pour le développement lors de sa 9e session plénière, qui s'est tenue au Mali (Bamako) en juin 2011.</p> <p>Le présent rapport comporte une analyse des raisons pour lesquelles des financements innovants dédiés à l'agriculture, à la sécurité alimentaire et à la nutrition sont nécessaires, propose un examen critique des mécanismes existants et possibles, et présente une sélection de méthodes pour mettre au point ces mécanismes. Il s'appuie à ces fins sur l'expertise du Comité d'experts de haut niveau, une analyse bibliographique, des réunions avec les professionnels concernés et la consultation en ligne organisée par le Forum global sur la sécurité alimentaire et la nutrition (Forum FSN).</p> <p>Le groupe de travail sur les financements innovants pour l'agriculture, la sécurité alimentaire et la nutrition a été créé pour relever les défis majeurs, actuels et futurs, auxquels la communauté</p> <p>[...]</p>
--	---

ELRC--- Atelier France 2016/05/11
16

**Gestion de données bilingues
Exemple (4/4)**

Alignement des deux versions

<p>S1. Executive Summary</p> <p>S2. This report is the result of a collective work carried out by the high-level expert Committee and a writing team commissioned by the Task Force on Innovative Financing for agriculture, food security and nutrition created by the Leading Group on Innovative Financing for Development at its 9th plenary session in Mali (Bamako) in June 2011.</p> <p>S3. The report includes an analysis of the need for innovating financing dedicated to the agricultural, food security and nutrition sector, a critical review of existing and possible mechanisms and a proposed selection of avenues for the development of such mechanisms on the basis of the expertise of a high-level Committee of experts, literature review, meetings with relevant professional actors and an on-line consultation on the Global Forum on food security and nutrition (FSN Forum)1.</p> <p>S4. The setting up of the Task Force on Innovative Financing for agriculture, food security and nutrition responds to current and future crucial challenges faced by the international community [...]</p>	<p>S1. Résumé</p> <p>S2. Le présent rapport résulte d'un travail collectif mené par le Comité d'experts de haut niveau et une équipe de rédacteurs désignés à cette fin par le groupe de travail sur les financements innovants pour l'agriculture, la sécurité alimentaire et la nutrition.</p> <p>S3. Ce groupe de travail a été créé par le Groupe pilote sur les financements innovants pour le développement lors de sa 9e session plénière, qui s'est tenue au Mali (Bamako) en juin 2011.</p> <p>S4. Le présent rapport comporte une analyse des raisons pour lesquelles des financements innovants dédiés à l'agriculture, à la sécurité alimentaire et à la nutrition sont nécessaires, propose un examen critique des mécanismes existants et possibles, et présente une sélection de méthodes pour mettre au point ces mécanismes.</p> <p>S5. Il s'appuie à ces fins sur l'expertise du Comité d'experts de haut niveau, une analyse bibliographique, des réunions avec les professionnels concernés et la consultation en ligne organisée par le Forum global sur la sécurité alimentaire et la nutrition (Forum FSN)1.</p> <p>S6. Le groupe de travail sur les financements innovants pour l'agriculture, la sécurité alimentaire et la nutrition a été créé pour relever les défis majeurs, actuels et futurs, auxquels la communauté [...]</p>
--	---

ELRC--- Atelier France 2016/05/11 17

L'organisation du flux de production des données

Données → Ressources Linguistiques

La chaîne de valeur

```

graph LR
    A[Identification & Sélection de données] --> B[Documentation]
    B --> C[Nettoyage & Conversion (contenu, format)]
    C --> D[Autres Traitements (e.g. Alignement)]
    D --> E[Validation]
    E --> F[Description & Stockage]
    
    G[détermination statut légal]
    H[PSI vs Licence]
    I[Vie privée (Privacy) (i.e. anonymisation)]
    
    G --- C
    H --- C
    I --- C
    
    J[Téléchargement données vers un dépôt « pérenne » Partage]
    F --- J
  
```

ELRC--- Atelier France 2016/05/11



Une meilleure alternative à cette chaîne



1/2

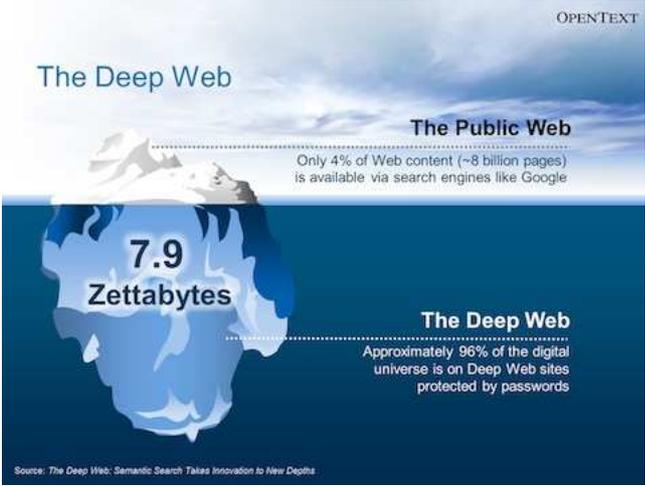
- On ne peut obtenir que la partie « visible » du web
- Il y a beaucoup plus dans les organisations publiques
- Nous avons besoin de votre aide pour identifier ces sources
- Ce processus peut aboutir à une « usine » de production de RLs
 - Automatisation de la procédure avec votre support

ELRC--- Atelier France 2016/05/11
19



Données visibles versus ...





Source: The Deep Web; Semantic Search Takes Innovation to New Depths

ELRC--- Atelier France 2016/05/11
20

European Language Resource Coordination
Connecting Europe Facility

... le Web « profond »

The diagram illustrates the web as an iceberg. The visible tip is the **SURFACE WEB**, containing Wikipedia, Google, and Bing. The much larger submerged part is the **DEEP WEB**, which includes Academic Information, Medical Records, Legal Documents, Scientific Reports, Subscription Information, Multilingual Databases, Conference Proceedings, Government Resources, Competitor Websites, and Organization-specific Repositories. The bottom, darkest part is the **DARK WEB**, containing Illegal Information, TOR-Encrypted sites, Drug Trafficking sites, and Private Communications. Two red circles highlight 'Medical Records' and 'Organization-specific Repositories' in the Deep Web section.

ELRC--- Atelier France 2016/05/11

21

European Language Resource Coordination
Connecting Europe Facility

Une meilleure alternative à cette chaine
2/2

- Ces documents existent déjà:
 - Dans les nombreux centres de documentation (Rapports, Brochures, Discours transcrits, fiches, des Mémoires de Traduction, Termino, ...)
 - Auprès de vos prestataires de services le.g. linguistiques (sous-traitants des travaux de traduction)
- **Nous avons besoin de votre assistance pour les identifier**

ELRC--- Atelier France 2016/05/11

22

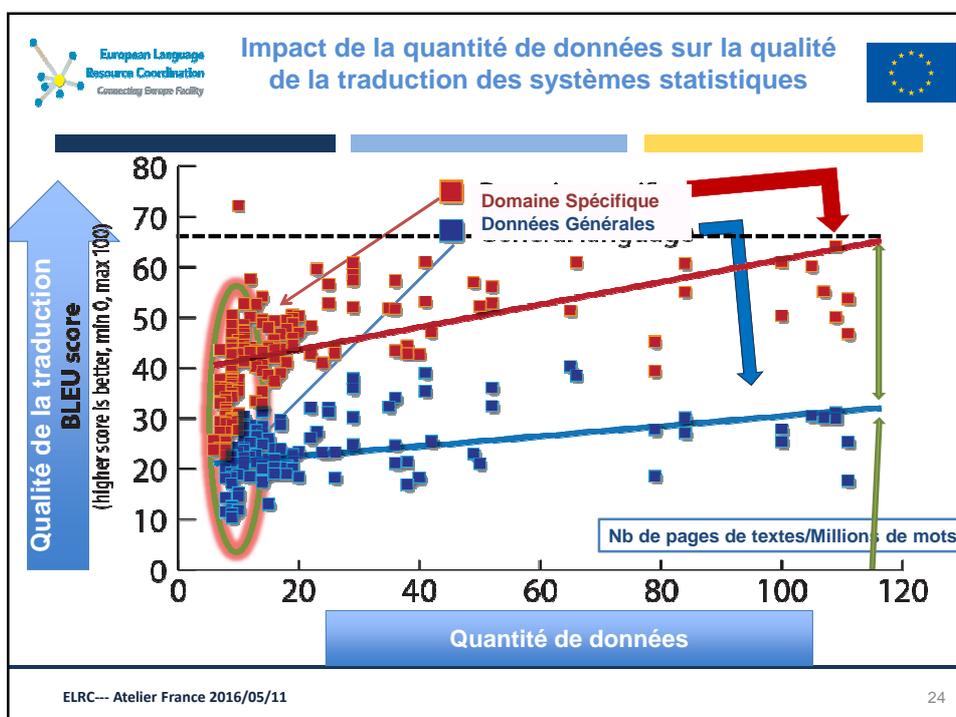
European Language Resource Coordination
Connecting Europe Facility



➤ De quelles données avons-nous besoin?

➤ **De combien de données avons-nous besoin ?**

ELRC--- Atelier France 2016/05/11 23





CONCLUSIONS



- Comment produit-on les données : essentiellement par des données existantes (développées pour d'autres finalités, réorientation/requalification, etc.)
- L'importance des données : Paradigme d'apprentissage (Data Driven Paradigm), encore plus exigeant avec les modèles de réseaux de neurones
- *Dans ce contexte, la valeur de vos données est inestimable*
- *Comment pouvez-vous contribuer à cet effort collectif?*
 - *Contribuer et bénéficier du CEF.AT*

ELRC--- Atelier France 2016/05/1125