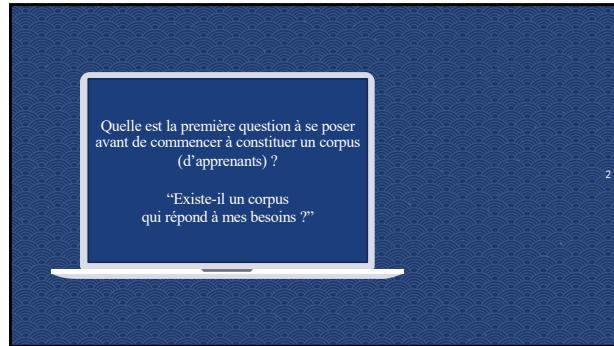
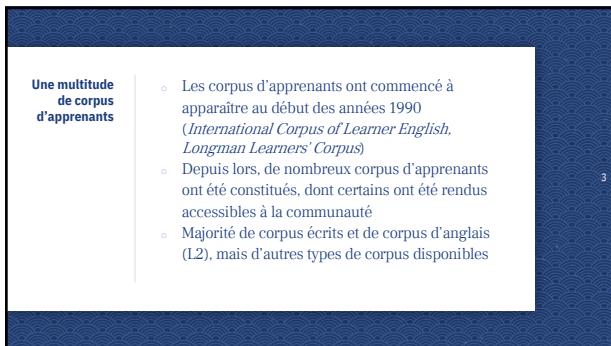




1



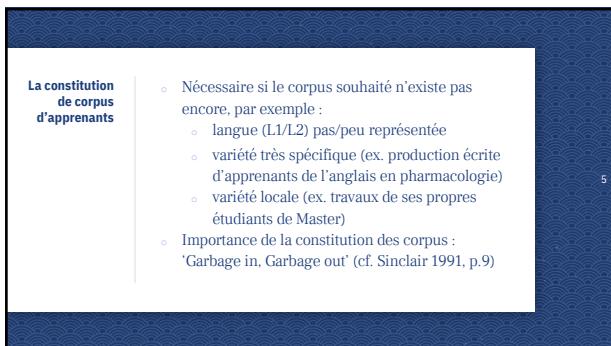
2



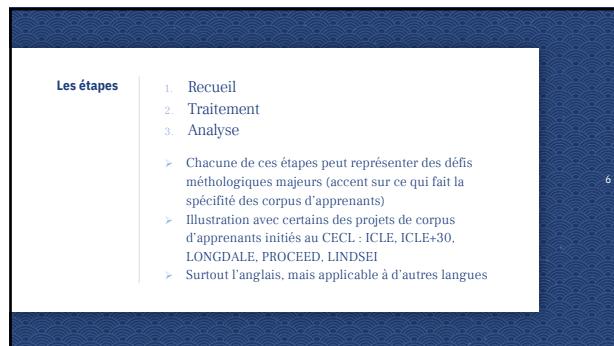
3

Learner corpora https://ulouvain.be/en/research-institutes/ilc/cecl/learner-corpora-around-the-world.html								
Use the query box below to search for specific keywords (e.g. languages, task type, medium).								
Corpus	First language	First language	Medium	Task type / task type	Proficiency level	Size in words	Project director	Availability
The "One Autrement" Corpus	French (Second Language)	French	Manly L1 speakers of English	Written	Narrative, descriptive, persuasive and informative texts	c. 50,000	Maria-Josée Hamel (Isolina Millovec (Dimitra Kotsopoulos), University, Canada)	Available after registration
French Monolingual Database (FRIDA)	French	Various	Written	Free writing, descriptive, argumentative texts, news & information texts, news & information texts	Intermediate		Sylviane Granger (Centre for English Corpus Linguistics, Université catholique de Louvain, Belgium)	
The Learner Corpus French (LCF)	French	Dutch	Written	Argumentative essays, descriptive texts, journalistic texts, formal letters, emails, newsletters, written contributions by Flemish students of French	Intermediate to advanced	c. 500,000	Hans Paalsteijn (KU Leuven/Ugent/Vleus, Belgium)	Under development
The Lund ICFL Corpus Collection (L1 French/L2 English)	French	Swedish	Written	Descriptive and narrative essays, picture-based stories	Various	c. 100,000	Malin Ågren (Lund University, Sweden)	A sub-part of the corpus is available online.

4

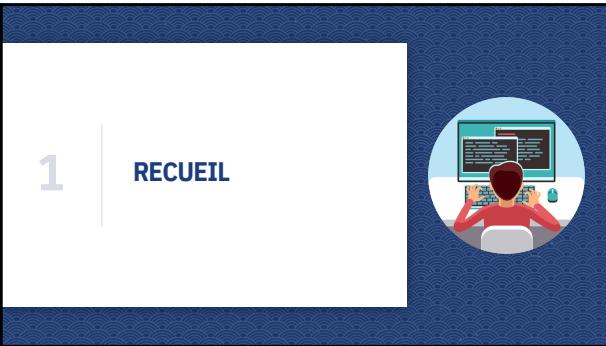


5



6

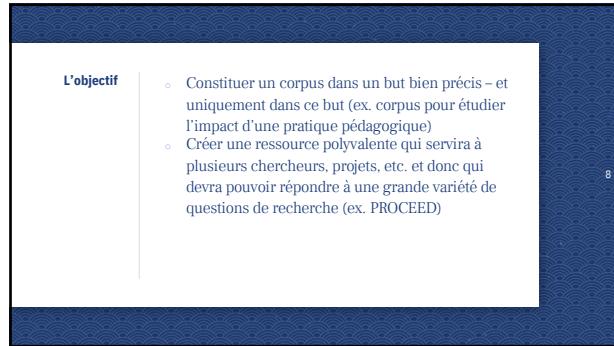
1



1

RECUEIL

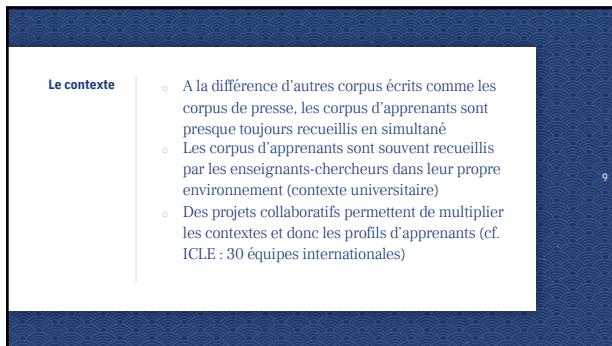
7



8

- Constituer un corpus dans un but bien précis – et uniquement dans ce but (ex. corpus pour étudier l'impact d'une pratique pédagogique)
- Crée une ressource polyvalente qui servira à plusieurs chercheurs, projets, etc. et donc qui devra pouvoir répondre à une grande variété de questions de recherche (ex. PROCEED)

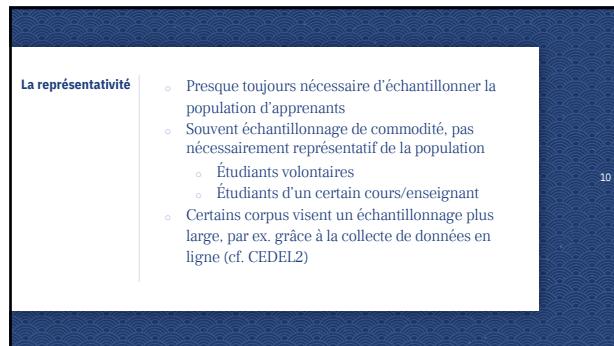
8



Le contexte

- A la différence d'autres corpus écrits comme les corpus de presse, les corpus d'apprenants sont presque toujours recueillis en simultané
- Les corpus d'apprenants sont souvent recueillis par les enseignants-rechercheurs dans leur propre environnement (contexte universitaire)
- Des projets collaboratifs permettent de multiplier les contextes et donc les profils d'apprenants (cf. ICLE : 30 équipes internationales)

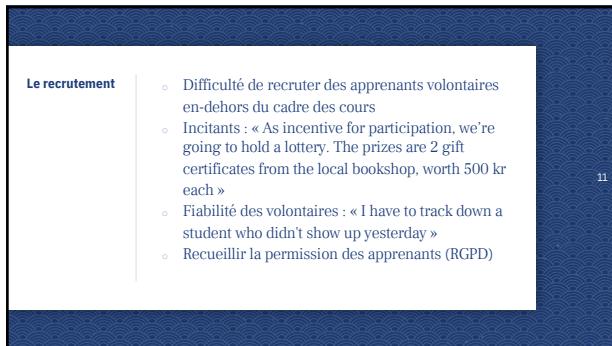
9



La représentativité

- Presque toujours nécessaire d'échantillonner la population d'apprenants
- Souvent échantillonnage de commodité, pas nécessairement représentatif de la population
 - Étudiants volontaires
 - Étudiants d'un certain cours/enseignant
- Certains corpus visent un échantillonnage plus large, par ex. grâce à la collecte de données en ligne (cf. CEDEL2)

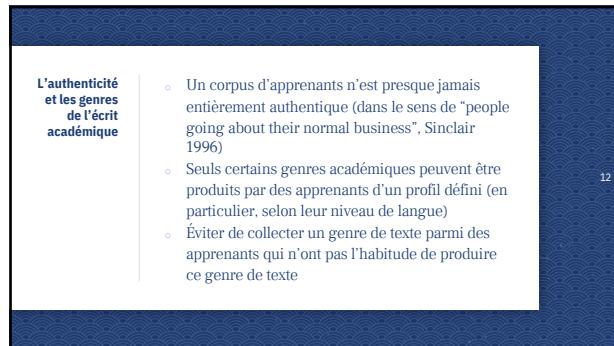
10



Le recrutement

- Difficulté de recruter des apprenants volontaires en-dehors du cadre des cours
- Incitants : « As incentive for participation, we're going to hold a lottery. The prizes are 2 gift certificates from the local bookshop, worth 500 kr each »
- Fiabilité des volontaires : « I have to track down a student who didn't show up yesterday »
- Recueillir la permission des apprenants (RGPD)

11



L'authenticité et les genres de l'écrit académique

- Un corpus d'apprenants n'est presque jamais entièrement authentique (dans le sens de "people going about their normal business", Sinclair 1996)
- Seuls certains genres académiques peuvent être produits par des apprenants d'un profil défini (en particulier, selon leur niveau de langue)
- Éviter de collecter un genre de texte parmi des apprenants qui n'ont pas l'habitude de produire ce genre de texte

12

11

12

2

Le cas des corpus longitudinaux

- Projets de longue durée (financement, personnel)
- Perte de participants (attrition)

Trajectory	Number of students
Y1	86
Y1-Y2	17
Y1-Y2-Y3	66
Y1-Y3	15
Y2	10
Y2-Y3	16
Y3	27
Total	237

LONGDALE (Paquot et al. 2021, p.129)

13

Les métadonnées

- Indispensable de collecter des métadonnées riches et détaillées, étant donné l'hétérogénéité des profils d'apprenants et l'influence de nombreuses variables sur la langue d'apprenants (Ellis 1994, Granger 1998)
- Sélection de variables potentiellement pertinentes, cf. Lozano (2021) (ex. interviewer dans LINDSEI)
- Niveau de compétence : si possible inclure le résultat d'un test standardisé, ex. LexTALE (limite des indicateurs de substitution, cf. Myles 2015, p.316)
- Impossible d'inclure toutes les variables pouvant influencer la langue d'apprenants (Granger 2004, p.126)

14

“Corpus-building is of necessity a marriage of perfection and pragmatism”
(McEnery et al. 2006, p.73)

15

2 TRAITEMENT



16

La numérisation

- Aujourd'hui, de nombreux corpus d'apprenants rassemblent des textes produits directement sous format électronique (cf. ICLE+30)
- Certains contextes où l'écriture à la main est encore de mise (ex. apprenants débutants, examens) => travail manuel de transposition
- Crucial de reproduire le texte exactement à l'identique - y compris les formes non-standard

17

Although the internet is a blessing for so many reasons such as a huge amount of information. Nevertheless, this technology is also a curse because too many people spend a lot of time on the internet surfing on useless websites. They are watching television, TV shows, movies during hours. Furthermore, they are wasting their time with social media like facebook, instagram, snap. Instead of using the internet in an intelligent, interesting way to my mind, it is a waste of time to spend hours on social media. These young people are more interested by their image.

18

Altough the internet is a bless for so many reason such as a huge amount of information . Neverthless , this technology (techno-logy?) is also a curse because young people spend a lot of time in the internet surfing on useless websites. They are watching television, TV shows , movies during hours . Furthermore , they are wasting their time with socialmedia (?) like facebook, instagram, snap.... Instead of using the internet in an (on?) intelligent , interesting way. To my mind, it is a waste of time spend hours on socialmedia (?). This young people are more interested by their image.

19

- L'anonymisation :
textes**
- So we got aquatinted a little bit . " Hi , my name is <name> and I went to high school in <place> . " (ICLE-BG)
 - The people who only saw my name often thought that I am a boy . (ICLE-KR)
 - The next day there I was sitting in class , I believe it was called Integrated Skills Course or some similar quasi intellectual and pretentious name . A very charismatic assistant professor was sharing her excitement , she was so glad to have us all there and boy did she sound British ! (ICLE-BG)

20

19

20

- L'anonymisation :
 métadonnées**
- Supprimer le nom n'est pas toujours suffisant, cf. Rocher et al. (2019) : identification d'un individu sur base de 16 attributs (dont la nationalité)
 - Données potentiellement sensibles, ex.
 - Langue maternelle : « if someone answers Kurdish or Sami, then that will tell us their ethnicity »
 - Niveau de compétence : « It could be easily turned into a ranking list of the different subcorpora and even the learners from different countries »

21

- Le balisage (1):
les citations**
- Importance de baliser tout texte écrit par autrui (⇒ corpus d'écrits académiques d'experts)
 - Exemple:
 - After about two hundred years an English writer George Orwell extended the statement in his novel Animal Farm : <quote> " All men are created equal but some are more equal than others . " </quote> (ICLE-CZ)

22

21

22

- Le balisage (2):
les révisions**
- Marburg corpus of Intermediate Learner English (Kreyer 2015)
- The inaugural speech <d><cd> <ads> written by</ad> Barack Obama, <lb></lb> shows us that America is at war and in <lb></lb> the midst of crisis. <lb></lb> He wants to explain, <lb></lb> that America need to stick together <lb></lb> work together. First of all he want's, that <lb></lb> all citizens <lb></lb> pick themselves up and begin with the remaining of America.
- Key: d: deleted text; ad: added text; lb: line break; ur: unreadable text.

23

- L'annotation (1)**
- La plupart des outils d'annotation actuels ont été créés pour annoter les variétés écrites natives / standard des langues (Gilquin & De Cock 2011)
 - Exemple : étiquetage morpho-syntaxique d'ICLE avec CLAWS
 - I could realized<VV> this fact (ICLE-GE)
 - Nowaday<NN1>, many educational programmes ... (ICLE-CN)
 - ... dreadful punishment againts<VVZ> Joan (ICLE-SP)

24

23

24

L'annotation (2)

- Résultats de l'étiquetage morpho-syntaxique et de l'analyse syntaxique de corpus d'apprenants généralement assez satisfaisants
 - Structure relativement simple des phrases (Meunier 1998, Huang et al. 2018)
 - Meilleurs résultats pour des niveaux de compétence avancés (Geertzen et al. 2014)
 - Peut varier selon les textes : 95%-99.1% de précision avec CLAWS sur ICLE (Granger et al. 2009, p.16)
 - Peut varier selon les catégories, ex. 100% pour JJR vs 33% pour VBO avec CLAWS sur LINDSEI

25

L'annotation (3): les erreurs

- L'annotation automatique d'erreurs est pour l'instant limitée à des phénomènes spécifiques, ex. prépositions (De Felice & Pulman 2009), articles (Rozovskaya & Roth 2010), orthographe (Rayson & Baron 2011)
- Comment identifier les erreurs ?
 - Études pilotes autour de l'identification d'erreurs par des locuteurs natifs : parfois plus du double d'erreurs identifiées par texte (Dagneaux et al. 2008, p.7)

26

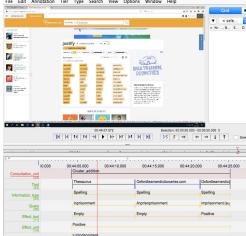
L'annotation (4): les erreurs

- Comment distinguer les erreurs de "maladresses"?
 - Louvain Error Tagging Manual (Dagneaux et al. 2008) : 'Errors' vs 'Infelicities' (ex. couldn't \$could not\$; him \$him/her\$) - sauf connecteurs et ponctuation ; quid des collocations (ex. high \$heavy\$ responsibilities) ?
- Comment déterminer la meilleure correction ?
 - Sometimes we cannot blame the masses for being (LS) narrow \$small-minded?\$. . .
 - If we were to assume that technological progress and human imagination are two irreconcilable things, then we would (LS) imminently \$?S be taking on a Romantic or even Luddite attitude.

27

L'annotation (5): autres

- Toute couche d'annotation augmente la valeur du corpus et permet de répondre à davantage de questions
- Impossible d'inclure tous les types d'annotation potentiellement utiles => à ajouter selon les besoins
- Process Corpus of English in Education (PROCEED : Gilquin 2022a) : annotation de l'utilisation d'outils d'aide à la rédaction (Gilquin & Laporte 2021)



28

“

"In practice, most annotation schemes ... aim at the maximum potential utility, tempered by the practicalities of annotating the text" (McEnery & Wilson 2001, p.34)

29

3 ANALYSE



30

L'objet de recherche (1): corpus-driven

- Privilégier une approche centrée sur le corpus / la langue d'apprenants, ex.
 - Recherche du mot *library* : 40 orthographes différentes dans un corpus d'anglais d'apprenants japonais (Milton & Okada 2007) : *libelary*, *literary*, *liburally*, *library*, *liveraly*, *liveray*, *liverey*, etc. (=>VariAnt, Anthony 2017)
 - Recherche de connecteurs sur base d'une liste pré-établie (Granger & Tyson 1996) => quid des connecteurs mal orthographiés (ex. *although*, *inspite*, *therefor*) ou non-standard (ex. *on the other side*, *according to me*) ?
 - "Recall problem" / "You-Don't-Know-What-You're-Missing problem" (Ball 1994, p.295)

31

L'objet de recherche (2): annotation

- Commencer par une étude pilote pour évaluer la précision de la recherche automatique (Granger 1997)
 - Recherche du passif (Granger 1997), ex.
 - *The reader is lead-nouns to believe that...*
 - *The laws aren't uphold<Vinf> that efficiently get.*
 - Recherche des constructions causatives avec *cause*, *get*, *have* et *make* (Gilquin 2016)
 - Inclusion de toutes les étiquettes correspondant à une forme verbale non-personnelle (infinitif, participe passé et présent), ex. *cause to decrease the crime rate* ; *makes people trying to find one*

32

Les facteurs d'influence (1)

- Les nombreux éléments du profil socio-linguistique de l'apprenant (et leur interaction !)
 - Souvent impossible d'effectuer un contrôle strict dans la sélection des données à cause de la taille du corpus (Callies 2015, p.52)
 - Interactions parfois difficiles à interpréter, cf. Deshors (2021) à propos des verbes à particule en anglais dans VOICE : type d'objet direct X rôle de l'orateur

33

Les facteurs d'influence (2)

- La tâche, y compris l'intitulé / le sujet

Bell et al. (2021, p.223-4) :
14 des 34 blocs lexicaux distinctifs de ICLE-FR (parmi ICLE) sont liés au sujet de la création de l'Europe, ex.

 - *Europe will be united against USA and Japan.*
 - *Each country will keep its own identity, currency, institutions and constitution.*

Image de deux policiers, d'un enfant et de sa mère
- Moins d'opportunités d'utiliser des mots féminins que masculins
- Incertitude quant au caractère correct ou incorrect des pronoms décrivant l'enfant

34

Les facteurs d'influence (3)

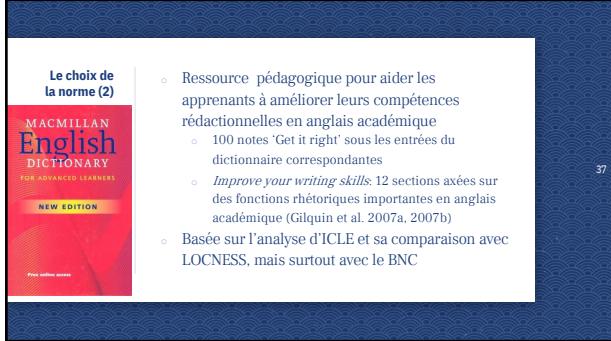
- La longueur des textes
 - La longueur des phrases tend à augmenter proportionnellement à la longueur des textes (Buttery & Caines 2012)
 - Les adverbes ont proportionnellement plus de chances d'être utilisés dans des textes plus longs (*ibid.*)
 - La nature et la fréquence des blocs lexicaux varie selon la longueur des textes (et le nombre de textes par corpus) (Pan et al. 2020)

35

Le choix de la norme (1) (Gilquin 2022b)

- Étudiants natifs ?
 - "Native-speaking students do not necessarily provide models that everyone would want to imitate" (Leech 1998, p.xix)
- Experts (natifs ou non-natifs) ?
 - "both unfair and descriptively inadequate" (Lorenz 1999, p.14)
 - "unrealistic standard of 'expert writer' models" (Hyland & Milton 1997, p.184)
- Étudiants natifs si évaluation ; experts si but formatif (Ådel 2006, p.206-207)

36



37

- Ressource pédagogique pour aider les apprenants à améliorer leurs compétences rédactionnelles en anglais académique
 - 100 notes 'Get it right' sous les entrées du dictionnaire correspondantes
 - *Improve your writing skills*: 12 sections axées sur des fonctions rhétoriques importantes en anglais académique (Gilquin et al. 2007a, 2007b)
- Basée sur l'analyse d'ICLE et sa comparaison avec LOCNESS, mais surtout avec le BNC

Personal Opinions

Most people have their own opinions about what's good or bad. If you're writing for the general public, it's important to make sure that your message is clear and accessible. In a general case, English speakers are inclined to use more formal language than other languages.

Get it right!

There are several points which need to be taken into account when writing for business purposes:

- 1. **Be clear and concise**: Make sure your message is clear and easy to understand. Avoid jargon and technical terms where possible.
- 2. **Use appropriate language**: Depending on the context, you may need to use more formal or more informal language. For example, if you're writing a report for your boss, you might want to use more formal language than if you're writing to a customer.
- 3. **Be professional**: Make sure your message is professional and polished. Avoid slang and colloquial language.

Explanations

When writing for business purposes, it's important to explain things clearly and concisely. This will help your audience understand what you're trying to say and why it's important.

Conclusion

When writing for business purposes, it's important to conclude your message effectively. This will help your audience remember what you've said and take action if necessary.

Business writing

Business writing is a type of writing that is used in business contexts. It is often used in reports, emails, and letters. Business writing is characterized by its formality and precision. It is also used in legal documents, such as contracts and agreements.

Expressing personal opinions

The most common way to express personal opinions is through the use of adjectives and adverbs. These can be used to describe the quality of something, such as 'good', 'bad', 'interesting', etc. They can also be used to express the level of agreement or disagreement with something, such as 'I think', 'I believe', etc.

Using your opinion explicitly

It's important to be explicit about your opinions when writing for business purposes. This means being clear about what you think and why you think it. It's also important to be honest and transparent in your writing.

Using your opinion implicitly

It's also possible to express your opinions implicitly, without saying them directly. This can be done through the use of tone, word choice, and punctuation. For example, if you write 'I think this is a good idea', you're expressing your opinion implicitly.

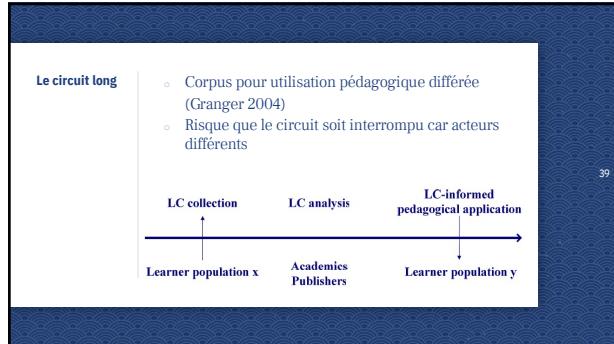
Requesting opinions

If you're writing for business purposes, it's important to request opinions from others. This can be done through the use of questions, such as 'What do you think?' or 'What do you believe?'. It's also important to be polite and尊重他人意见.

Expressing possibility and probability

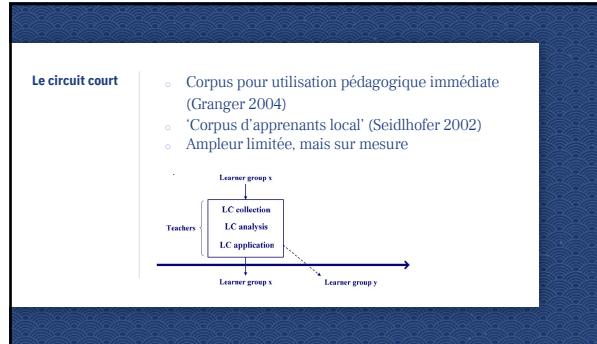
When writing for business purposes, it's important to express the possibility and probability of certain events occurring. This can be done through the use of modal verbs, such as 'can', 'will', 'may', etc. It's also important to be realistic and accurate in your predictions.

38

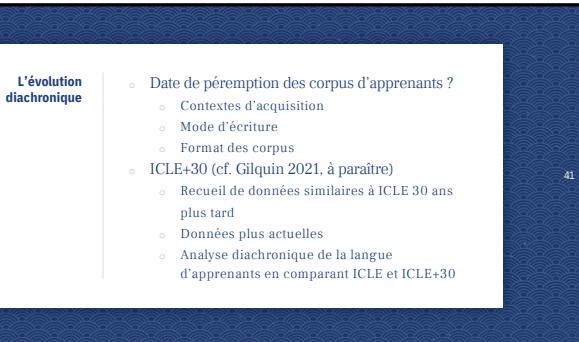


39

- Corpus pour utilisation pédagogique différée (Granger 2004)
- Risque que le circuit soit interrompu car acteurs différents



40



41

“Every corpus I have had the chance to examine, however small, has taught me facts I couldn't imagine finding out any other way”
(Fillmore 1992, p.35)

42



43



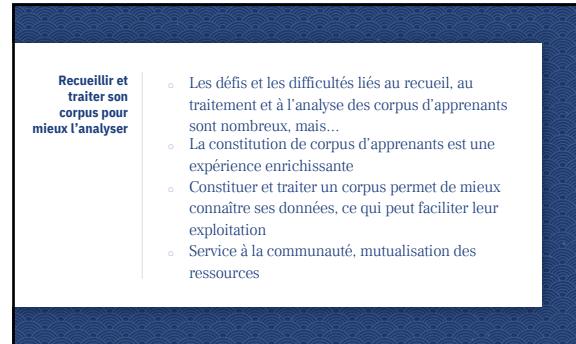
45

45



47

47



44

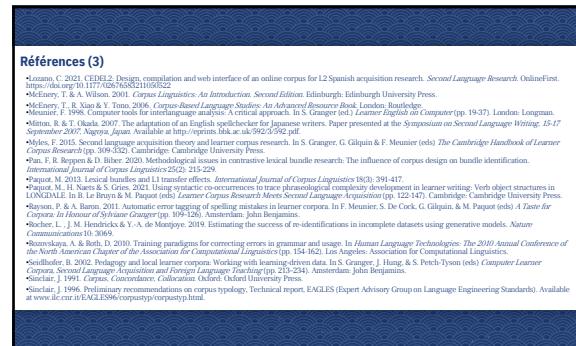
44



46

46

48



8