

## КОНТЕКСТНО-АСОЦІАТИВНИЙ ПІДХІД ДО АВТОМАТИЗОВАНОГО ВИПРАВЛЕННЯ ОРФОГРАФІЧНИХ ПОМИЛОК

### Вступ

Характер постановки та шляхи вирішення задачі автоматизованого виправлення орфографічних помилок у текстових даних різняться у залежності від масштабу та призначення відповідних інформаційних систем. Основою функціонування більшості автокоректорів є використання морфологічних моделей частин природної мови та результатів синтаксичного аналізу контексту слова з помилкою. Перевірка узгодженості за змістом варіантів виправлення спотвореного слова з його контекстним оточенням, як правило, не входить до функціональних профілів систем реального часу через високий ступінь складності алгоритмів її реалізації.

Сучасні досягнення у галузі створення *lingware* дозволяють вивести на якісно новий рівень вирішення задачі встановлення семантичної відповідності варіантів виправлення спотвореного слова його контексту. У даній роботі доводиться доцільність використання контекстно-асоціативного підходу до відбору варіантів виправлення під час проведення орфокорекції в реальному часі, а також пропонується модифікація загальноприйнятої схеми корекції для підвищення точності виправлення орфографічних помилок прикладними програмними засобами із покращенням часових характеристик роботи останніх.

### Сучасний стан проблеми побудови програмних автокоректорів

На сьогоднішній день більшість систем автоматичної обробки текстів (АОТ), зокрема орфокоректори, працюють відповідно до класичної послідовної схеми аналізу даних (морфологічний, синтаксичний, семантичний рівні аналізу, причому «результати кожного попереднього рівня є вихідною інформацією для наступних» [1]). Звідси, перевірка семантичної узгодженості варіантів виправлення із контекстним оточенням спотвореного слова (якщо вона взагалі передбачена) має розміщуватися наприкінці алгоритму орфокорекції [2]. Але, не дивлячись на сучасний прогрес у галузі побудови *lingware*, розробники систем реального часу найчастіше взагалі уникають використання семантичного аналізу даних та віддають перевагу підвищенню ефективності роботи коректорів за рахунок створення нових алгоритмів формального підбору варіантів виправлення спотвореного слова. На жаль, у такий спосіб не вдається істотно покращити точність отримуваних результатів, тому коректори повертають користувачеві список усіх варіантів виправлення, які задовольняють формальним критеріям близькості слів, але за змістом не відповідають контексту [3-5]. У таких випадках остаточний вибір вірного варіанту покладається на людину.

Між тим, фахівці у галузі побудови систем АОТ наголошують на відсутності функціональної ізольованості етапів аналізу природномовного тексту. Згідно цього, морфологічний аналіз може не лише надавати вихідні дані для синтаксичного та семантичного аналізу, але і використовувати результати їх роботи [6-9]. Звідси, на думку авторів, порушення класичної схеми аналізу тексту повинне сприяти використанню у повній мірі можливостей семантичного рівня аналізу текстів для підвищення точності та швидкості роботи програмного забезпечення виправлення орфографічних помилок.

### Вихідна схема автоматизованого виправлення орфографічних помилок

Загальноприйнята схема автоматизованої корекції спотвореного слова [10] передбачає реалізацію:

- етапу висунення гіпотез (вірогідних варіантів виправлення помилки) і
- етапу перевірки гіпотез та ухвалення однієї (декількох) з них як виправлення, що пропонується програмою до внесення.

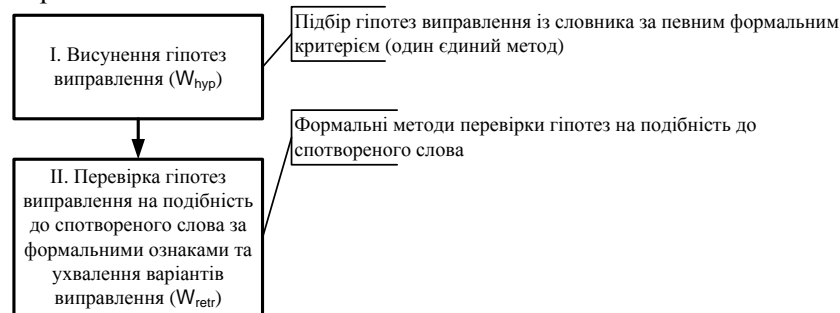
На першому етапі послідовно виконуються *підбір* первинної множини варіантів виправлення із словника та *попередня фільтрація* її вмісту. Для реалізації даного етапу використовуються *найпростіші* та *найшвидші* методи пошуку варіантів корекції слова (наприклад, підбір гіпотез за критерієм альфакоду, довжини слова, збігу першої літери слова тощо) [10].

На другому етапі виконується перевірка гіпотез на подібність до спотвореного слова за

певними критеріями. Тут задіяні більш *складні*, але, водночас, і більш *точні* методи аналізу набору гіпотез (наприклад, відстань редагування В.Левенштейна) [5, 10, 11].

Таким чином, умовне віднесення методів визначення варіантів виправлення орфографічних помилок до певного етапу процесу орфокорекції здійснюється на основі їх характеристик (швидкості, точності тощо).

З іншого боку, всі методи перевірки гіпотез виправлення (на обох етапах) по своїй суті є фільтрами заданої множини слів, адже в результаті застосування кожного з них відбувається звуження поточної множини варіантів корекції спотвореного слова. З огляду на це у даній роботі пропонується внести уточнення в подання вихідної схеми орфокорекції (див. рис. 1): будемо вважати таким, що відноситься до етапу висунення гіпотез, тільки метод підбору гіпотез виправлення із словника; усі ж методи фільтрації множини слів, отриманої на першому етапі, перенесемо до другого етапу – етапу перевірки гіпотез.



**Рис.1. Вихідна схема виправлення орфографічних помилок**

Для оцінки ефективності роботи програмних засобів машинної корекції помилок, введемо функцію фільтрації заданої множини слів за певною ознакою.

*Визначення 1.* Функція  $filter: W_x \rightarrow W_y$  називається фільтром множини  $W_x$ , якщо за її допомогою з елементів  $W_x$  проводиться формування множини слів  $W_y$ , які відповідають певному критерію схожості із спотвореним словом  $error\_word$  ( $W_y \subseteq W_x$ ).

$$filter: W_x \rightarrow W_y, W_y \subseteq W_x, \quad (1)$$

де  $W_x, W_y$  - множини природномовних слів.

Властивостями даної функції є:

- 1)  $filter(W_A \cup W_B) = filter(W_A) \cup filter(W_B)$  (2);

- 2) якщо  $|W_A| < |W_B|$ , то час, необхідний для виконання фільтрації даних множин, характеризується нерівністю  $t filter(W_A) < t filter(W_B)$  (3);

- 3) при застосуванні композиції фільтрів  $F = filter_n \circ filter_{n-1} \circ \dots \circ filter_2 \circ filter_1: W_x \rightarrow W_y, W_y \subseteq W_x$  до множини слів  $W_x$  від перестановки складових  $filter_i$  місцями результат  $W_y$  не змінюється.

Тривалість виконання даних функцій, навпаки, змінюється у залежності від порядку їх застосування.

Оскільки функції, які застосовуються у межах етапу перевірки гіпотез (див. рис.1), є фільтрами, їм притаманні властивості визначеної вище функції  $filter$ .

Позначимо функцію, за допомогою якої проводиться підбір гіпотез виправлення  $W_{hyp}$  зі словника, як

$$fI: W_{dict} \rightarrow W_{hyp}, W_{hyp} \subseteq W_{dict} \quad (4)$$

Вважатимемо, що  $fI$  забезпечує висунення оптимальної (за показниками кількості слів, міри їх формальної схожості на спотворене слово  $error\_word$  та швидкості отримання) множини гіпотез  $W_{hyp}$  для її ефективної перевірки на наступному етапі орфокорекції. Час, протягом якого триває виконання  $fI$ , позначимо як  $t_I = t fI(W_{dict})$ .

Фільтри, котрі використовуються на *етапі перевірки гіпотез*, позначимо

$$FII = fII_m \circ fII_{m-1} \circ \dots \circ fII_i \circ \dots \circ fII_2 \circ fII_1 : W_{hyp} \rightarrow W_{retr}, \quad m \geq 1, \quad (5)$$

де  $fII_i : WII_{i-1} \rightarrow WII_i$  ( $i = 1, 2, \dots, m$ ) – фільтр множини слів, отриманої у результаті виконання  $fII_{i-1}$  (для  $fII_1$  - множини  $W_{hyp}$ );  $W_{retr}$  - множина слів, визначених коректором як можливі варіанти виправлення за формальними ознаками їх близькості до спотвореного слова.

Будемо вважати, що  $FII$  містить необхідний та достатній набір функцій, послідовне застосування яких до множини  $W_{hyp}$  забезпечує оптимальне співвідношення часу

отриманого результату.  $t_{II} = t_{fII_1}(W_{hyp}) + \sum_{k=2}^m t_{fII_k}(WII_{k-1})$ , витраченого на виконання зазначених функцій, та точності

Оскільки визначення гіпотез виправлення здійснюється шляхом їх *пошуку* в словнику (а не за допомогою безсловникової генерації), при визначенні показників ефективності орфокоорекції можна провести певні паралелі з оцінками результатів роботи програм у теорії інформаційного пошуку [12].

**Визначення 2.** Під точністю машинної орфографічної корекції спотвореного слова матимемо на увазі відношення числа запропонованих орфокооректором вірних варіантів написання слова (це одиниця або нуль), до загальної кількості підібраних слів.

$$PRECISION = \frac{|W_{corr} \cap W_{retr}|}{|W_{retr}|}, \quad (6)$$

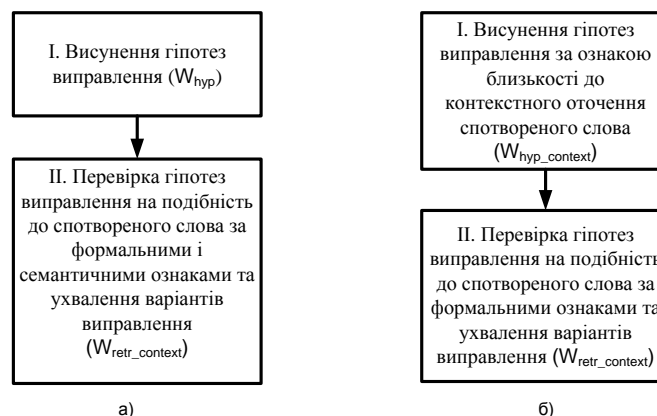
де  $W_{corr}$  - множина вірних варіантів корекції спотвореного слова у словнику.

Відповідно до формули (6), для того, щоб досягти високого показника точності роботи орфокооректора, необхідно, по-перше, забезпечити постійне входження вірного слова до сформованого масиву варіантів виправлення ( $|W_{corr} \cap W_{retr}| = 1$ ), а по-друге, - зменшити загальну кількість слів, які пропонуються програмою як найбільш вірогідні кандидати виправлення помилки ( $W_{retr}$ ).

### Місце семантичної складової у модифікованій схемі виправлення орфографічних помилок

Розглянемо можливі варіанти модифікації вихідної схеми орфокоорекції шляхом введення до різних її етапів семантичної складової, а також проаналізуємо, як дані зміни вплинуть на показники точності та швидкості роботи відповідної програми.

Формування множини гіпотез виправлення за семантичним критерієм із заданого набору слів здійснюватимемо за допомогою функції  $f_{cont}$ . Визначимо дану функцію як фільтр, за допомогою якого виконується відбір із вихідного набору слів тих лексем, що узгоджені з контекстним оточенням спотвореного слова.



**Рис.2. Варіанти модифікації схеми виправлення орфографічних помилок**

**I варіант** (див. рис. 2а) – введення контекстно-асоціативної фільтрації до етапу перевірки гіпотез виправлення.

Оскільки склад композиції функцій  $FII$  за визначенням (див. формулу 5) є необхідним та

достатнім для ефективної обробки гіпотез виправлення, будь-які зміни у ньому спричинять зниження ефективності роботи орфоко렉тора хоча б за одним з показників. Крім того, повна заміна формальних процедур перевірки слів  $FII$  семантичною  $f_{cont}$  неможлива, оскільки варіанти виправлення мають відповідати як вимогам контекстної близькості, так і формальним критеріям схожості слів. Тому проаналізуємо можливість поєднання  $f_{cont}$  та  $FII$  без внесення змін до складу останньої:

$$FII' = fII_m \circ fII_{m-1} \circ \dots \circ fII_i \circ f_{cont} \circ fII_{i-1} \circ \dots \circ fII_2 \circ fII_1 : W_{hyp} \rightarrow W_{retr\_context}, \quad m \geq 1, \quad (7)$$

де  $W_{retr\_context}$  - множина слів, визначених як можливі варіанти виправлення спотвореного слова з урахуванням семантики його контексту.

*Твердження 1.* Введення функції  $f_{cont}$  до послідовності формальних фільтрів  $FII$  сприяє підвищенню точності роботи коректора (*PRECISION*).

*Доведення.* Нехай  $WII_{i-1}$  - результат фільтрації множини  $W_{hyp}$  із використанням композиції функцій  $fII_{i-1} \circ \dots \circ fII_2 \circ fII_1 : W_{hyp} \rightarrow WII_{i-1}$  (для  $i=1$  роль  $WII_{i-1}$  виконує безпосередньо  $W_{hyp}$ ). Для  $FII$  та  $FII'$  вміст  $WII_{i-1}$  є однаковим, адже вихідна множина гіпотез і набір функцій, які до неї застосовуються, у цих двох випадках не відрізняються.  $f_{cont}$  за визначенням є фільтром, тому справедливим є твердження  $f_{cont} : WII_{i-1} \rightarrow WIIcont_{i-1}$ ,  $WIIcont_{i-1} \subseteq WII_{i-1}$ , де  $WIIcont_{i-1}$  - результат фільтрації слів з  $WII_{i-1}$  за ознакою близькості за змістом до контекстного оточення спотвореного слова. Звідси маємо:

$$WIIcont_{i-1} \cup \Delta W_{cont\_out} = WII_{i-1}, \quad (8)$$

де  $\Delta W_{cont\_out}$  - частина множини  $WII_{i-1}$ , яка була виключена із подальшої обробки через невідповідність семантичному критерію фільтрації слів.

Перевірка множин  $WII_{i-1}$  та  $WIIcont_{i-1}$  за допомогою функцій, які входять до складу композицій  $FII$  та  $FII'$  відповідно, проводиться, починаючи з фільтру  $fII_i$ :

- $WII_{i-1} \xrightarrow{fII_i} WII_i, \quad WII_i \subseteq WII_{i-1};$
- $WIIcont_{i-1} \xrightarrow{fII_i} WIIcont_i, \quad WIIcont_i \subseteq WIIcont_{i-1}.$

Відповідно до (2) та (8) можна записати:  $fII_i(WII_{i-1}) = fII_i(WIIcont_{i-1}) \cup fII_i(\Delta W_{cont\_out}) \Rightarrow WII_i = WIIcont_i \cup fII_i(\Delta W_{cont\_out}) \Rightarrow |WIIcont_i| \leq |WII_i|.$

Застосування фільтру  $fII_{i+1}$  характеризується аналогічним чином:  $WII_i \xrightarrow{fII_{i+1}} WII_{i+1}, \quad WII_{i+1} \subseteq WII_i$  і  $WIIcont_i \xrightarrow{fII_{i+1}} WIIcont_{i+1}, \quad WIIcont_{i+1} \subseteq WIIcont_i$ . Звідси  $fII_{i+1}(WII_i) = fII_{i+1}(WIIcont_i) \cup fII_{i+1} \circ fII_i(\Delta W_{cont\_out}) \Rightarrow WII_{i+1} = WIIcont_{i+1} \cup fII_{i+1} \circ fII_i(\Delta W_{cont\_out}) \Rightarrow |WIIcont_{i+1}| \leq |WII_{i+1}|.$

У результаті отримуємо:

$$\begin{aligned} fII_m(WII_{m-1}) &= fII_m(WIIcont_{m-1}) \cup fII_m \circ fII_{m-1} \circ \dots \circ fII_i(\Delta W_{cont\_out}) \Rightarrow \\ W_{retr} = WII_m &= WIIcont_m \cup fII_m \circ fII_{m-1} \circ \dots \circ fII_i(\Delta W_{cont\_out}) = W_{retr\_context} \cup fII_m \circ fII_{m-1} \circ \dots \circ fII_i(\Delta W_{cont\_out}) \Rightarrow \\ |W_{retr\_context}| &\leq |W_{retr}|. \end{aligned}$$

Отже, відповідно до (6) введення семантичної функції  $f_{cont}$  до послідовності формальних фільтрів  $FII$  забезпечує підвищення точності роботи коректора (*PRECISION*), завдяки проведенню більш ретельної фільтрації гіпотез виправлення, що і необхідно було довести.

Тут необхідно відмітити, що місце розташування функції  $f_{cont}$  у композиції фільтрів  $FII$ , згідно з властивістю (3) функції *filter*, не впливає на точність роботи відповідної програми.

Проаналізуємо, як зміниться *швидкодія* машинного орфоко렉тора при доповненні композиції

*FI* фільтром  $f_{cont}$ .

*Твердження 2.* Для збереження швидкодії даної модифікованої схеми необхідне виконання нерівності

$${}^t f_{cont}(W\Pi_{i-1}) \ll {}^t f\Pi_m \circ f\Pi_{m-1} \circ \dots \circ f\Pi_i(\Delta W_{cont\_out}) \quad (9)$$

*Доведення.* Будемо порівнювати час виконання *FI* та *FI'*, починаючи від наступної за  $f\Pi_{i-1}$  функції ( $f\Pi_i$  та  $f_{cont}$  відповідно), адже частина  $f\Pi_{i-1} \circ \dots \circ f\Pi_2 \circ f\Pi_1 : W_{hyp} \rightarrow W\Pi_{i-1}$  є спільною для обох композицій. Для того, щоб швидкість роботи коректора за наведеною модифікованою схемою була не нижчою за швидкість роботи вихідної схеми, має виконуватися нерівність:

$${}^t f_{cont}(W\Pi_{i-1}) + \sum_{k=i}^m {}^t f\Pi_k(W\Pi_{cont_{k-1}}) \ll \sum_{k=i}^m {}^t f\Pi_k(W\Pi_{k-1}) \quad (10)$$

Вище було доведено, що  $|W\Pi_{cont_k}| \ll |W\Pi_k|$ , де  $k = i-1, i, \dots, m$ . Тому, виходячи з властивості функції *filter* (див.(3)), отримуємо  $\sum_{k=i}^m {}^t f\Pi_k(W\Pi_{cont_{k-1}}) \ll \sum_{k=i}^m {}^t f\Pi_k(W\Pi_{k-1})$ . А на основі того, що  $W\Pi_{cont_k}$  відрізняється від  $W\Pi_k$  на множину  $f\Pi_k \circ \dots \circ f\Pi_{i+1} \circ f\Pi_i(\Delta W_{cont\_out})$ , де  $k \geq i$ , можна зробити такий висновок: час, витрачений на фільтрацію  $f_{cont}$  має бути компенсований за рахунок того, що певна частина гіпотез з  $W\Pi_{i-1}$  потрапила до  $\Delta W_{cont\_out}$  і не буде оброблятися наступними функціями, що і відображено у записі (9).

Виконанню нерівності (9) сприятиме невисока (така, що не перевищує складності формальних фільтрів) складність алгоритму семантичної фільтрації.

Як *Наслідок 1* даного твердження можна розглядати таку залежність: чим ближче до початку послідовності формальних фільтрів *FI* розташовано семантичну функцію  $f_{cont}$ , тим більше функцій входять до композиції  $f\Pi_m \circ \dots \circ f\Pi_{i+1} \circ f\Pi_i(\Delta W_{cont\_out})$  з правої частини нерівності (9), і, отже, тим вища імовірність успішної компенсації часу  ${}^t f_{cont}(W\Pi_{i-1})$ .

Звідси, розташування  $f_{cont}$  наприкінці послідовності *FI* (тобто  $f_{cont} \circ f\Pi_m \circ f\Pi_{m-1} \circ \dots \circ f\Pi_1(W_{hyp})$ ) не забезпечує покращення швидкодії орфокоректора, оскільки на виконання функції  $f_{cont}$  витрачається додатковий час. Отже, такий варіант модифікації схеми орфокорекції є окремим випадком введення контекстно-асоціативної фільтрації до етапу перевірки гіпотез виправлення, і може бути використаний при побудові коректорів, для яких високий показник точності результатів має вищий пріоритет, ніж швидкість роботи програми.

Таким чином, введення семантичного фільтру до етапу перевірки гіпотез забезпечує підвищення точності орфокорекції, а за виконання умови (9) - і прискорення роботи програми. При цьому множина гіпотез виправлення формується шляхом підбору лексем із словника за *формальною ознакою* схожості із спотвореним словом.

Розглянемо інший випадок модифікації схеми автоматизованої орфокорекції, коли визначення варіантів виправлення *error\_word* починається з виконання  $f_{cont}$  (тобто коли  $f_{cont}$  виконує роль  $fI$  і, відповідно, розташована на етапі висунення гіпотез).

**II варіант** (див. рис. 2б) – **висунення гіпотез виправлення за ознакою семантичної близькості до контекстного оточення спотвореного слова *error\_word*.**

Необхідно зазначити, що при введенні  $f_{cont}$  замість  $fI$  до етапу перевірки гіпотез має бути додана функція фільтрації множини варіантів виправлення за формальним критерієм, відповідно до якого виконувалося висунення гіпотез. Це вмотивовано тим, що відсутність перевірки лексем за критерієм подібності до *error\_word*, яку реалізувала  $fI$  під час підбору гіпотез із словника, може негативно вплинути на точність роботи орфокоректора.

Окремо потрібно зупинитися на тому, що ефективно висунення гіпотез виправлення за

ознакою семантичної близькості до контексту спотвореного слова можливе лише за умови використання коректором якісно укладеного лексико-семантичного словника. Цей лінгвістичний ресурс, як правило, має просту та зрозумілу форму опису знань і подається у вигляді орієнтованого графу  $G = (W_{dict}, E)$ , вершинами котрого є лексеми природної мови  $W_{dict}$ , пов'язані між собою лексико-семантичними відношеннями з множини  $E$  [13]. Така архітектура словника відповідає принципам організації пам'яті людини, є близькою до семантичної структури природномовних фраз, а також дозволяє кількісно обчислювати міру близькості слів за змістом.

*Твердження 1a.* Введення семантичної функції  $f_{cont}$  до етапу висунення гіпотез схеми орфокоорекції сприяє підвищенню точності роботи коректора (*PRECISION*).

*Доведення.* Відправною точкою доведення є факт, що потужність множини  $W_{dict\_cont}$ , отриманої шляхом аналізу вмісту словника функцією  $f_{cont}$ , є меншою, ніж вміст цілого словника, а значить можна стверджувати, що  $W_{dict\_cont} \cup \Delta W_{cont\_out} = W_{dict}$ . Даний вираз є подібним до (8). Звідси подальше доведення *Твердження 1a* відбувається аналогічно до доведення *Твердження 1*.

*Твердження 2a.* Для прискорення функціонування коректора, алгоритм роботи якого передбачає висунення гіпотез за ознакою семантичної близькості до контексту спотвореного слова, у порівнянні із коректором, що працює за вихідною схемою, необхідна справедливість нерівності:

$${}^t f_{cont}(W_{dict}) - {}^t fl(W_{dict}) \leq {}^t fl_{m^{\circ} \dots \circ fl_1}(W_{hyp}) - {}^t fl_{m^{\circ} \dots \circ fl_1 \circ fl}(W_{hyp\_cont}) \quad (11)$$

*Доведення.* Мета, відповідно до якої ми модифікуємо схему орфокоорекції, - це зменшення сумарного часу виконання етапів виправлення помилок:

$${}^t f_{cont}(W_{dict}) + {}^t fl_{m^{\circ} \dots \circ fl_1 \circ fl}(W_{hyp\_cont}) \leq {}^t fl(W_{dict}) + {}^t fl_{m^{\circ} \dots \circ fl_1}(W_{hyp}), \quad (12)$$

де  $W_{hyp\_cont}$  - множина лексем, відібраних за семантичним критерієм із словника. Перенесення певних доданків з однієї частини нерівності до іншої дозволяє отримати запис (11), що і потрібно було довести.

Визначення позиції семантичної функції у загальній схемі машинної орфокоорекції, яка забезпечила б *оптимальне* співвідношення швидкодії орфокооректора та рівня точності результатів виправлення, слід проводити, виходячи з того, який принцип формування набору слів, близьких за змістом до заданого контексту, покладений в основу роботи функції  $f_{cont}$ .

На основі властивості 2) функції *filter*, а також згідно з (6) можна зробити висновок про те, що показники швидкості та точності роботи програмного забезпечення орфокоорекції залежать від потужності множин слів, котрі ним обробляються. Таким чином, враховуючи особливості реалізації  $f_{cont}$ , а також характеристики текстових даних та лексико-семантичних ресурсів, неважко визначити ефективний варіант модифікації схеми орфокоорекції для кожного конкретного випадку.

Наприклад, у коректорі, що працює на базі лексико-семантичного ресурсу формату WordNet 3.0, а міру семантичної близькості до контексту обчислює як мінімальну з довжин найкоротших шляхів від заданого слова до елементів контексту за структурою графу  $G$ , семантичну функцію доцільно застосовувати на етапі висунення гіпотез виправлення.

Зробимо декілька ремарок відносно подальшого вивчення контекстноорієнтованого підходу до визначення варіантів вправлення спотвореного слова.

**1.** Залучення елементів семантичного аналізу тексту на початкових кроках процесу корекції у жодному разі не виключає подальшого проведення синтаксичного та семантичного аналізу тексту. Це пояснюється тим, що помилки, які перетворюють слово на іншу лексему, котра присутня у словнику, можуть бути виявлені та виправлені виключно на синтактико-семантичному рівні аналізу тексту. Отже, з точки зору розробки кінцевого програмного продукту практичний інтерес становить вивчення можливості використання допоміжних даних, отриманих під час орфокоорекції, на наступних кроках автоматизованої обробки тексту.

2. Автори вважають, що сферою застосування підходу до висування гіпотез виправлення за семантичним критерієм, у межах якої він є ефективним, є алгоритми роботи інформаційно-пошукових систем (ІПС).

По-перше, корекція слів у такому випадку не потребує синтаксичного узгодження варіантів виправлення, адже для ІПС важливим є визначення базової форми слова.

По-друге, у ролі контексту можуть виступати всі слова запиту. Відносно невелика кількість слів у запитах (~ 71% запитів складаються з 2-4 слів [14]) не є перешкодою для застосування семантичного аналізу, тому що навіть одне вірно написане ключове слово може визначити область пошуку варіантів виправлення.

По-третє, користувач під час складання запиту до ІПС намагається використовувати ключові слова, які найбільш адекватно відображають його інформаційну потребу та є максимально семантично навантаженими. Тому імовірність швидкої та точної обробки пошукових запитів є високою.

3. Алгоритми роботи *lingware* часто є евристичними і базуються на емпіричних дослідженнях [7, 8]. Тому доцільним є проведення практичного вивчення закономірностей у послідовності вживання типів семантичних відношень у процесі руху словником.

4. Визначення оптимальної комбінації фільтрів, використання якої покращувало б роботу орфокооректора за показниками швидкодії та точності, є багатокритеріальною задачею, котра не має універсального розв'язку. Звідси її потрібно вирішувати, виходячи з конкретних умов роботи програми.

5. Для налаштування автокооректора на роботу з текстами певної предметної галузі у відповідному словнику необхідно ввести додаткове ранжування слів за критерієм відповідності їх тематиці галузі.

## Висновки

Обґрунтовано доцільність відхилення від класичної схеми аналізу текстових даних у межах машинного виправлення орфографічних помилок, а отже і введення контекстно-асоціативного аналізу оточення спотвореного слова до будь-якого етапу корекції.

Дано визначення показника ефективності функціонування орфокооректора – точності результатів його роботи; показано, що, як і швидкодія, вона залежить від кількості слів, що обробляються під час корекції.

Доведено факт підвищення точності та визначено умови покращення часових характеристик роботи відповідної програми при введенні до схеми орфокоорекції додаткової функції відбору варіантів виправлення за семантичним критерієм. Таким чином, показана можливість реалізації семантичної складової в алгоритмах роботи орфокооректорів в реальному часі.

Розглянуто перспективні напрямки подальшого вивчення проблеми контекстно-асоціативного визначення варіантів вправлення спотвореного слова.

## Література

1. Т.Грязнухіна, Н.Дарчук, Л.Олексієнко Система автоматичного аналізу українського наукового тексту //Проблеми українізації комп'ютерів. Тези доповідей Л., 1991. с.19-20
2. Johannes Schaback and Fang Li Multi-Level Feature Extraction for Spelling Correction In Proceedings of the IJCAI-2007 Workshop on Analytics for Noisy Unstructured Text Data (Hyderabad, India - January 8, 2007) pp.79-86
3. Лавошникова Э.К. Об организации системных словарей компьютерных//НТИ, сер.2. 2004. - №9. – с.31-38
4. Лавошникова Э.К. О компьютерной коррекции «популярных» ошибок в текстах на русском языке. НТИ. 2003, №9. - с.28-34
5. Кондратюк Д. Корекція орфографічних помилок в українському тексті // Проблеми українізації комп'ютерів: Матеріали 2-ї міжнар. конф. (Львів, 29 вересня- 1 жовтня 1992 р.) / Інститут кібернетики ім. В.М.Глушкова / Р.П. Базилевич (відп.за вип.), М.М. Онопрієнко— К., 1992. — с.51 – 55
6. Марченко О.О. Алгоритми семантичного аналізу природномовних текстів: Дис.канд.фіз.-мат. наук:01.05.01/ КНУ ім. Тараса Шевченка. — К., 2005. — 150 с.

7. Леонтьева Н.Н. «Политекст»: информационный анализ политических текстов. НТИ сер.2. 1995 с. 4 – 17
8. Белоногов Г.Г., Дуганова И.С. и др. Экспериментальная система автоматизированного обнаружения и исправления орфографических ошибок в текстах//НТИ. Сер.2. – 1984. - №3. – с.20-22
9. Бондаренко М.Ф., Осыка А.Ф. Автоматическая обработка информации на естественном языке. – К.: УМК ВО, 1991. – 144с.
10. Машинное понимание текстов с ошибками/В.С.Файн, Л.И.Рубанов. – М.:Наука,1991. – 151с.
11. Михайлюк А.Ю., Заболотня Т.М. Комбінований метод виправлення орфографічних помилок у текстових даних // Вісник Хмельницького національного університету. – №2. – Т.2. – 2007. – С.21-26.
12. Пещак М.М. Нариси з комп'ютерної лінгвістики:Монографія. – Ужгород:Закарпаття, 1999. – 200с.
13. Базы знаний интеллектуальных систем/ Т.А.Гаврилова, В.Ф.Хорошевский – СПб: Питер, 2000. – 384 с.
14. Ландэ Д.В. Поиск знаний в Internet / [Ред. А.В.Слепцов]. — М. и др.: Диалектика, 2005. — 271 с.: ил., табл.. — (Профессиональная работа)