© Wydawnictwo UR 2018 „Edukacja – Technika – Informatyka” nr 1/23/2018
ISSN 2080-9069 www.eti.rzeszow.pl
ISSN 2450-9221 online DOI: 10.15584/eti.2018.1.3

ARTUR ZACNIEWSKI[1], MARCIN KLEINSZMIDT[2], RADOSŁAW ZDUNEK[3], JOANNA ZACNIEWSKA[4]

Analiza algorytmów syntezy mowy na potrzeby zastosowania w urządzeniu przenośnym

Analysis of Speech Synthesis Algorithms for the Purposes of Deployment in Embeddeddevice

[1] Doktor inżynier, Akademia Marynarki Wojennej w Gdyni, Wydział Nawigacji i Uzbrojenia Okrętowego, Zakład Informatyki, Polska
[2] Magister inżynier, Toucan Systems, Sp. z o.o., Gdańsk, Polska
[3] Magister inżynier, Toucan Systems, Sp. z o.o., Gdańsk, Polska
[4] Doktor, Wyższa Szkoła Komunikacji Społecznej w Gdyni, Wydział Nauk Społecznych, Polska

Streszczenie

W artykule pokazano kolejne etapy występujące w syntezie mowy, a także sposoby postępowania z poszczególnymi fragmentami tekstu, który ma zostać przetworzony na mowę. Przedstawiono wyniki badań wydajności algorytmów normalizacji treści, realizowanych na potrzeby projektu ToucanEye – urządzenia przenośnego z systemem sztucznej inteligencji, mającego wspomóc osoby z dysfunkcją wzroku. Pokazano, jak istotne jest dobranie i optymalizacja zastosowanych algorytmów ze strony implementacyjnej, po to by zwiększyć komfort użytkownika końcowego.

Słowa kluczowe: synteza mowy, wspomaganie osób z dysfunkcją wzroku, ToucanEye

Abstract

The article presents consecutivestages of speech synthesis and also ways of dealing with particular fragments of text are shown. The article also presents results of performance measurement for text content normalization algorithms, developed for the Toucan Eye project – embedded device with artificial intelligence system able to help people with impaired sight. It was shown how essential is choice and optimization of applied algorithmsfrom implementation side to increase comfort of end-user.

Keywords: speech synthesis, assisting persons with impaired sight, ToucanEye

Wstęp

W skład systemów sztucznej inteligencji wspomagających osoby z dysfunkcją wzroku bardzo często wchodzi system syntezy mowy. Na wejście takiego

systemu podawany jest tekst, np. z systemu przetwarzania obrazów, który wykrywa, przetwarza i rozpoznaje tekst znajdujący się w zasięgu użytkownika urządzenia.

Synteza mowy jest wieloetapowym procesem, którego efektem końcowym jest wytworzenie sygnału audio zawierającego tekst, w sposób możliwie przypominający efekt, jaki dałoby przeczytanie tego tekstu przez człowieka. W procesie syntezy mowy wyróżnić można dwa etapy:

– przetwarzanie tekstu naturalnego NLP (ang. *Natural Language Processing*), który zawiera szereg procesów wykonywanych po stronie tekstowej, przede wszystkim normalizacja tekstu, ale także zwrócenie uwagi na niuanse kontekstowe, które mogą zmieniać pożądany sposób wymówienia danego słowa (dotyczy to zwłaszcza liczb, gdzie skomplikowane reguły koniugacyjne czynią to zadanie stosunkowo złożonym),

– synteza właściwa, w której algorytm pracujący najczęściej na odpowiednio przygotowanym zestawie próbek zajmuje się przetwarzaniem spreparowanego już tekstu na sygnał audio (PJWSTK, 2017).

Gdzieś pomiędzy nimi istnieje jeszcze subtelna warstwa intonacji i akcentowania, bardzo czytelna dla człowieka, choć niebezpośrednio rzutująca na poziom zrozumienia samego tekstu, a więc komunikacja – wciąż werbalna, ale nieprzywiązana ściśle do tekstu – niosąca dodatkowe informacje o stanie emocjonalnym osoby czytającej tekst w trakcie zdania (Delgado, Araki, Neto, 2005).

Zmiany szybkości czytania, melodii głosu czy akcentowanie poszczególnych wyrazów czy głosek mogą sugerować skupienie uwagi na konkretnych aspektach wypowiadanej frazy. Jest to jednak zagadnienie mocno złożone – nawet najlepsze na świecie syntezatory mowy w pewnych sytuacjach potrafią zabrzmieć nienaturalnie. Efekty te stanowić mogą najwyżej o pewnym wzroście komfortu czy naturalności obcowania z systemem, ale nie wpływają w znacznym stopniu na skuteczność systemu jako pomocy dla osób z upośledzeniem wzroku.

Dobór i optymalizacja ww. algorytmów są niezmiernie ważne dla uzyskania satysfakcjonujących wyników, stąd wyłania się ważna rola kształcenia inżynierskiego twórców i osób implementujących te algorytmy. W tym przypadku urządzenie ma być używane przez osoby niewidome i niedowidzące i to właśnie od właściwej inżynierskiej implementacji i optymalizacji konkretnych metod zależeć będzie skuteczność i komfort użytkowania urządzenia ToucanEye. Stąd przydatność ww. metod w kształceniu inżynierskim wydaje się oczywista. Ich zrozumienie i umiejętność praktycznego wykorzystania przez inżyniera może pozwolić na ułatwienia kształcenia osobom z różnego rodzaju dysfunkcjami wzroku.

Algorytmy normalizacji tekstu

Normalizacja tekstu ma za zadanie przetworzenia tekstu i nadanie mu spójnej formy ułatwiającej dalszą interpretację. Założeniem normalizacji jest zmiana formy przetwarzanego tekstu z formy pisanej na mówioną. Ze względu na zło-

żoność i różnorodność języka polskiego normalizacja treści nie jest zadaniem trywialnym, składa się z dużej ilości złożonych etapów, a w wielu przypadkach wymaga stworzenia nowych mechanizmów przetwarzających tekst w sposób, który będzie pomocny dla przyszłych użytkowników.

Przygotowanie tekstu, który następnie zostanie przekazany do syntezy mowy, nie jest zagadnieniem prostym i od jakości tego przygotowania w dużej mierze zależy jakość i zrozumiałość mowy. Podejście do przygotowania treści będzie odmienne dla różnych języków i dialektów, gdyż każdy ma inną składnię i reguły językowe (Łopatka, Czyżewski, 2010).

Fazy obejmujące zadanie normalizacji tekstu to:

– tokenizacja, czyli przekształcenie tekstów w usystematyzowany zbiór „tokenów" (znaczników z polami pomocnymi przy dalszej obróbce i analizie); pomaga algorytmowi w „zrozumieniu" poszczególnych części tekstu, determinuje, w jaki sposób ma być interpretowane dane słowo w kontekście oraz w otaczającej je treści,

– odrzucenie słów i znaków nieistotnych lub zamiana ich na znaki równoważne (np. dla syntezy mowy wymowa „ó" będzie taka sama jak „u"),

– zamiana wyrazów z wybranych grup tokenów na reprezentację słowną danego wyrażenia; odrębnych mechanizmów translacji (m.in. tworzenia słowników) wymagają liczby naturalne, liczby rzeczywiste, liczby poprzedzone lub zakończone symbolami, daty, godziny, symbole i znaki, skróty i skrótowce, adresy e-mail, strony WWW, znaki tabulacji lub końca linii (NKJP, 2017).

Faza ta obejmuje czynności, których człowiek posługujący się biegle językiem nie dostrzega i nie zdaje sobie sprawy z ich stopnia trudności. Przykładowo problem można dostrzec u obcokrajowców próbujących nauczyć się języka polskiego, mają oni spore trudności z dobraniem odpowiedniej formy wypowiedzi i takie same problemy napotykają twórcy algorytmów przygotowujących tekst do syntezy mowy (Graliński i in., 2006).

Tokenizacja

W kolejnych etapach działania algorytmu badania kontekstu tokeny mogą zostać uzupełniane kolejnymi informacjami potrzebnymi z punktu widzenia syntezy mowy. Przykładem takim może być klasyfikacja znaków, np. przecinka lub dwukropka. Znaki takie określają sposób czytania następujących po nich treści.

Token może być reprezentowany w standardzie XML (ang. *Extensible Markup Language*). Rozwiązanie takie jest proste i efektywne, w pełni wystarczające dla potrzeb projektu. Każdy token zawiera pole "id", dzięki czemu algorytm może sprawdzić wcześniejsze i kolejne słowa podczas analizy kontekstu lub odtworzyć tekst wejściowy. Kolejnym polem jest "word", gdzie przechowywana jest oryginalna wartość słowa. Pole "type" określa typ słowa. Determinuje on metody późniejszego przetwarzania danych słów. Pole "value" zawiera tłumaczenie znaków niebędących literami na odpowiednią interpretację słowną. War-

tość tego pola będzie dalej modyfikowana i w ostatniej fazie tłumaczona na słowniki fonetyczne (Perkins, 2014).

Struktura tokenuma następującą budowę:

<te id=”ID_słowa_w_treści” word=”słowo” type=”typ_słowa” value=”” />

Przykład tokenizacji dla tekstu “Sklep otwarty od 08:30”:

<te id=”1” word=”Sklep” type=”wordFirstUppercase” value=”sklep” />
<te id=”2” word=”otwarty” type=”wordLowercase” value=”otwarty” />
<te id=”3” word=”od” type=”wordLowercase” value=”od” />
<te id=”4” word=”08:30” type=”hour” value=”ósmatrzydzieści” />

Tokenizacja tekstu pozwala na wskazanie metodzie translacyjnej, w jaki sposób dane słowo ma zostać odczytane. Umiejętność dobrania odpowiedniej metody i sposobu translacji jest podstawowym zagadnieniem efektywnej syntezy mowy. Oczyszczanie tokenów ma na celu usunięcie pól niemających znaczenia dla dalszych etapów syntezy mowy, co pozwala na przyspieszenie działania algorytmu oraz poprawę jakości syntezowanej mowy. Na potrzeby badań opracowano algorytmy normalizacji dla wszystkich ww. grup, ale ze względu na objętość artykułu pokazano tylko wybrane (Sołdacki, 2006).

Algorytm normalizacji tekstu – daty

Przebieg pracy algorytmu dla rozpoznanej daty niezawierającej spacji:

– Na początku algorytm wykonuje detekcję znaków rozdzielających datę, mogą nimi być znaki: ‘/’, ‘-’, lub ‘.’.

– W następnym kroku ustalana jest pozycja dnia oraz roku w dacie przy założeniu pozycji miesiąca pośrodku daty, tak jak ma to miejsce w ustalonym formacie daty dla Polski.

– Następnie data oraz rok są zamieniane z formy liczbowej na pisaną przy użyciu algorytmu do zamiany liczb naturalnych. Dodatkowo algorytm do zamiany roku na wejściu otrzymuje informację, aby korzystać z innego słownika zawierającego formy specjalnie przygotowane dla niego.

– W ostatnim kroku miesiąc jest zamieniany zgodnie ze słownikiem Miesiące, gdzie ewentualne zero przed liczbą jest usuwane.

Metoda ta jest stosowana dla tokenów posiadających typ ‘date’. Złożoność tej metody podkreśla fakt, że data może być zapisywana na wiele sposobów. Dodatkowo odczytanie może być różne dla odmiennych przypadków. Algorytm będzie oczekiwał 3 wartości:

– dzień miesiąca w formacie 1–31, w tym dla dat 1–9 może być poprzedzone 0,

– numer miesiąca w postaci liczb arabskich, rzymskich lub w postaci skrótu oraz pełnej nazwy miesiąca,

– rok w postaci YYYY lub YY.

Wartości te mogą występować w różnej kolejności i mogą być oddzielane znakami:

- spacją (DD MM YYYY),
- myślnikami (DD-MM-YYYY),
- kropkami (DD.MM.YYYY),
- ukośnikami (DD/MM/YYYY),
- mieszane (DD MM, YYYY).

Skuteczność (stosunek poprawnie rozpoznanych dat do liczby wszystkich badanych dat) opisywanej metody dla składowych rozdzielonych znakiem '-' lub '.' (kropką) wyniosła w badaniach 97,5%.

Dla normalizacji godzin (typ 'hour') uzyskano skuteczność ok. 95%. Błędy wynikały ze złego doboru formy wypowiedzi dla niektórych przypadków.

Algorytm normalizacji tekstu – skróty i skrótowce

Ta metoda jest używana dla tokenów typu 'shortcut' i powinna być rozpatrywana względem wartości liczby mnogiej lub pojedynczej. Do realizacji opisanej metody konieczne jest zdefiniowanie dwóch zbiorów. Algorytm tworzy na ich podstawie słowniki. Jeden dla skrótów zakończonych kropkami, np.: inż., p.n.e. oraz drugi dla skrótów bez kropek, np.: PLN, zł, ABW, RP. Jeśli badane słowo pasuje do wzorca dla skrótów z kropką, algorytm przeszukuje odpowiedni słownik oraz jeśli występuje w nim klucz odpowiadający skrótowi, zwraca jego rozwiniętą formę. W przeciwnym razie, jeśli badane słowo nie pasuje do wzorca, tzn. nie zawiera kropki, algorytm przeszukuje słownik, w którym znajdują się skróty bez kropek. Jeśli znajdzie odpowiedni klucz, zwraca jego wartość. Obecnie lista skrótów liczy ok. 200 pozycji. Skuteczność opisywanego algorytmu wynosi 90%.

W przypadku normalizacji liczb naturalnych (typ 'numberNatural') dla 500 losowo wygenerowanych liczb z zakresu 1–9 999 999 999 999 999 999 uzyskano skuteczność 100%.

Algorytmy normalizacji tekstu – liczby rzymskie

Algorytm polega na zamianie liczb rzymskich na arabskie, następnie wynik operacji przekazywany jest do opisanej już metody normalizacji liczb arabskich. W systemie rzymskim liczby zapisywane są od lewej do prawej, zaczynając od liczb o największej wartości. Istnieją wyjątki od tej reguły dla liczby 4 oraz 9 i ich krotności dziesiętnych.

Algorytm został przebadany na grupie 520 losowo wygenerowanych liczb w formacie rzymskim w zakresie 1–2050. Skuteczność opisywanego algorytmu to ok. 99,9%. Jedyny błąd algorytmu to zakwalifikowanie liczby 'CV' jako skrótu i odczytanie jej jako 'curriculum vitae'.

Algorytmy transkrypcji fonetycznej

Tekst, który przeszedł już przez wszystkie etapy normalizacji, nie nadaje się jeszcze do syntezy, gdyż sam tekst w postaci słownej nie niesie żadnych informacji o sposobie wypowiedzi. Nie pozwala on na jednoznaczne określenie wymowy danego wyrazu. Dobrym przykładem obrazującym problem może być słowo auto, gdzie „u" musi zostać przeczytane jako „ł" (Tadeusiewicz, 1998).

Do zapisu wymowy może służyć alfabet fonetyczny IPA (ang. *International Phonetic Alphabet*) lub SAMPA (ang. *Speech Assessment Methods Phonetic Alphabet*). Translacja polega na zamianie liter danych wejściowych na odpowiadające im symbole w danym alfabecie fonetycznym. Należy także wyróżnić reguły precyzujące translację wyjątków dla języka polskiego. W tabeli 1 pokazano translację znaków wykorzystywaną podczas badań. Alfabet SAMPA zapisywany jest w kodzie ASCII, dzięki czemu korzystanie z niego jest bardziej praktyczne dla deweloperów.

Tabela 1. Translacja znaków w alfabecie SAMPA

Symbol	SAMPA	Symbol	SAMPA	Symbol	SAMPA
a	a	k	k	w	v
ą	o~	l	l	y	I
b	b	ł	w	z	z
c	c	m	m	ź	z'
ć	ts'	n	n	ż	Z
d	d	ń	n'	sz	S
e	e	o	o	ś	ts
ę	e~	p	p	dz	dz
f	f	r	r	cz	tS
g	g	s	s	dż	dZ
h	x	t	t	dź	dz'
i	i	u	u	rz	Z
j	j	ó	u		

Źródło: SAMPA (2017).

Wydajność metod normalizacji treści

Szybkość działania metod normalizacji tekstu ma kluczowy wpływ na działanie całej syntezy, gdyż zbyt długie przetwarzanie tekstu wydłuży czas oczekiwania na dźwięk, co w konsekwencji może prowadzić do tego, że urządzenie będzie czytało napisy, które już nie są istotne dla użytkownika. Testy zostały przeprowadzone na komputerze z procesorem Intel Core i5-4460 oraz 8 GB pamięci RAM. Programy testowe zaimplementowano w języku C# wraz z graficznym interfejsem użytkownika (GUI), pokazanym na rysunku 1.

Do sprawdzenia wydajności przygotowano 10 zdań o różnej długości, zawierających elementy wymagające translacji lub usunięcia (liczby arabskie, rzymskie, daty, godziny, skróty oraz znaki interpunkcyjne). Czasy wykonywania poszczególnych operacji przedstawia tabela 2, przy czym X-SAMPA to rozszerzony alfabet SAMPA.

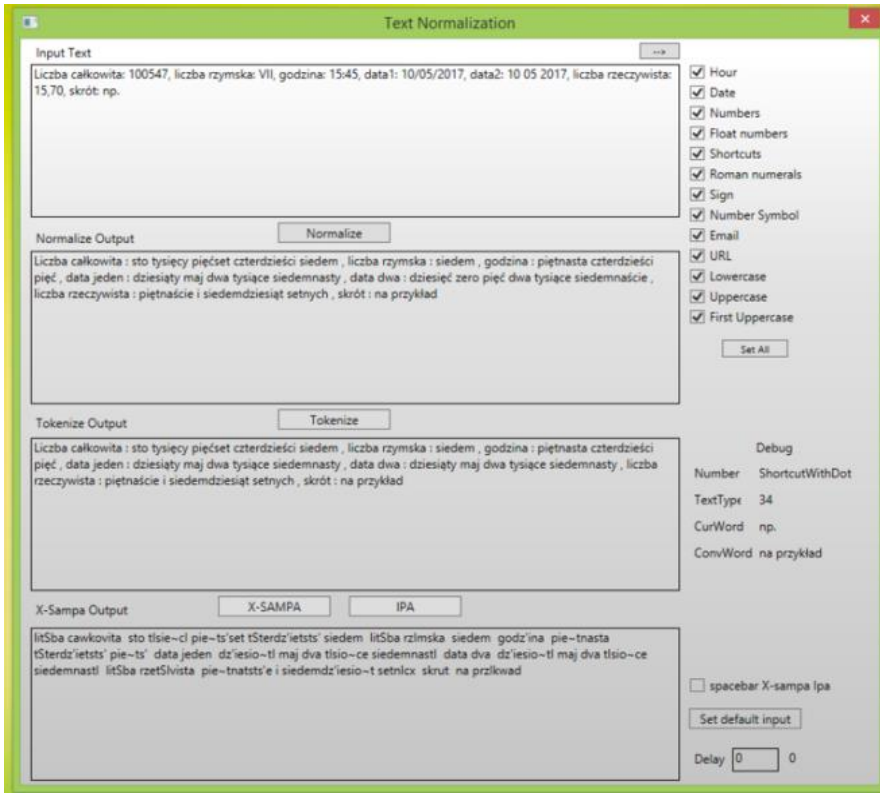

Rysunek 1. GUI programu do normalizacji treści

Źródło: opracowanie własne.

Tabela 2. Wydajność metod normalizacji treści

Liczba znaków w tekście	Czasnormalizacji (ms)	Czastokenizacji (ms)	Czas translacji X-SAMPA (ms)	Całkowitycz as (ms)	Użycie CPU (%)	Użycie RAM (MB)
214	3,000	3,125	1,571	7,696	8	60
9	2,142	2,428	1,285	5,857	4	60
1124	8,875	6,875	3,500	19,250	15	60
1760	13,75	7,000	5,125	25,875	17	62
717	8,000	6,000	2,375	16,375	14	60
92	3,375	3,500	1,250	8,125	12	60
1786	14,125	8,500	5,500	28,125	20	62
1343	11,250	6,875	3,625	21,750	10	60
Średnia:	**8,064**	**5,537**	**3,029**	**14,784**	**12,5**	**60,5**

Źródło: opracowanie własne.

Średnia czasu normalizacji to ok. 15 ms. Przy uwzględnieniu, że w badaniu wykorzystano kilka długich fragmentów tekstu (1700 znaków – 3 akapity tekstu), możemy uznać wynik za zadowalający. Całkowity czas syntezy to suma

czasów normalizacji treści i syntezy mowy, inaczej mówiąc, jest to czas od momentu podania tekstu na wejście systemu syntezy mowy do momentu rozpoczęcia odczytu przez urządzenie.

Podczas analizy wydajności algorytmu ważnym elementem jest również koszt obliczeniowy danej metody. W projekcie ToucanEye, na potrzeby którego realizowane były ww. algorytmy i badania, ma to szczególne znaczenie, gdyż urządzenie powinno mieć kompaktowe rozmiary, a zasilanie będzie bateryjne. Średnie użycie procesora dla przykładów opisanych powyżej to 12,5 %, a średnie wykorzystanie pamięci RAM to 60,5 MB.

Podsumowanie

Analizując wydajność mechanizmów i algorytmów normalizacji tekstu, można stwierdzić, że zarówno czas potrzebny na przetwarzania treści, jak i wykorzystanie zasobów są na bardzo niskim poziomie i nie powinny mieć wpływu na działanie urządzenia. Dalsze praktyczne testy pozwolą na weryfikację osiągniętych rezultatów.

Literatura

Delgado, R., Araki, M., Neto, J. (2005). *Spoken, Multilingual and Multimodal Dialogue Systems: Development and Assesment*. Richmond: Wiley.

Graliński, J., Jassem, K., Wagner, A., Wypych, M. (2006). Linguistic Aspects of Text Normalization in Polish Text-to-speech System. *System Science*, *32* (4), 7–15.

Łopatka, K., Czyżewski, A. (2010). Syntetyzer mowy uwzględniający prozodię wypowiedzi. *Zeszyty Naukowe Wydziału Elektrotechniki i Automatyki Politechniki Gdańskiej*, *28*, 105–108.

NKJP (2018). Pobrane z: http://nkjp.pl/ (1.09.2017).

Perkins, J. (2014). *Python 3 Text Processing with NLTK 3 Cookbook*. Birmingham: Packt Publishing.

PJWSTK (2017). Pobrane z: http://syntezamowy.pjwstk.edu.pl/synteza.html (1.09.2017).

SAMPA (2017). Pobrane z: http://www.phon.ucl.ac.uk/home/sampa/ (1.09.2017).

Sołdacki, P. (2006). *Zastosowanie metod płytkiej analizy tekstu do przetwarzania dokumentów w języku polskim*. Rozprawa doktorska, Warszawa: Politechnika Warszawska, Wydział Elektroniki i Technik Informacyjnych.

Tadeusiewicz, R. (1988). *Sygnał mowy*. Warszawa: Wydawnictwa Komunikacji i Łączności.