

THE ICELANDIC LANGUAGE IN THE DIGITAL AGE

ÍSLENSK TUNGA Á STAFRÆNNI ÖLD

Eiríkur Rögnvaldsson
Kristín M. Jóhannsdóttir
Sigrún Helgadóttir
Steinþór Steingrímsson

White Paper Series

Hvítbókaröð

THE ICELANDIC
LANGUAGE IN
THE DIGITAL
AGE

ÍSLENSK
TUNGA Á
STAFRÆNNI
ÖLD

Eiríkur Rögnvaldsson Háskóla Íslands
Kristín M. Jóhannsdóttir Háskóla Íslands
Sigrún Helgadóttir Árnastofnun
Steinþór Steingrímsson Háskóla Íslands

Georg Rehm, Hans Uszkoreit
(ritstjórar, editors)

Editors

Georg Rehm
DFKI
Alt-Moabit 91c
Berlin 10559
Germany
e-mail: georg.rehm@dfki.de

Hans Uszkoreit
DFKI
Alt-Moabit 91c
Berlin 10559
Germany
e-mail: hans.uszkoreit@dfki.de

ISSN 2194-1416
ISBN 978-3-642-30173-5
DOI 10.1007/978-3-642-30174-2
Springer Heidelberg New York Dordrecht London

ISSN 2194-1424 (electronic)
ISBN 978-3-642-30174-2 (eBook)

Library of Congress Control Number: 2012939477

© Springer-Verlag Berlin Heidelberg 2012

This work is subject to copyright. All rights are reserved by the Publisher, whether the whole or part of the material is concerned, specifically the rights of translation, reprinting, reuse of illustrations, recitation, broadcasting, reproduction on microfilms or in any other physical way, and transmission or information storage and retrieval, electronic adaptation, computer software, or by similar or dissimilar methodology now known or hereafter developed. Exempted from this legal reservation are brief excerpts in connection with reviews or scholarly analysis or material supplied specifically for the purpose of being entered and executed on a computer system, for exclusive use by the purchaser of the work. Duplication of this publication or parts thereof is permitted only under the provisions of the Copyright Law of the Publisher's location, in its current version, and permission for use must always be obtained from Springer. Permissions for use may be obtained through RightsLink at the Copyright Clearance Center. Violations are liable to prosecution under the respective Copyright Law.

The use of general descriptive names, registered names, trademarks, service marks, etc. in this publication does not imply, even in the absence of a specific statement, that such names are exempt from the relevant protective laws and regulations and therefore free for general use.

While the advice and information in this book are believed to be true and accurate at the date of publication, neither the authors nor the editors nor the publisher can accept any legal responsibility for any errors or omissions that may be made. The publisher makes no warranty, express or implied, with respect to the material contained herein.

Printed on acid-free paper

Springer is part of Springer Science+Business Media (www.springer.com)



FORMÁLI

PREFACE

Þessi hvítbók er hluti af ritröð til kynningar á máltaekni og möguleikum hennar. Henni er einkum beint til fólks sem starfar í menntageiranum, á fjölmöldum, í stjórnrmálum – og í raun til málsamfélagsins í heild. Aðgengi að máltaekni og notkun hennar er mjög mismunandi milli tungumála í Evrópu. Þar af leiðir að aðgerðir sem nauðsynlegar eru til að styðja rannsóknir og þróunarstarf í máltaekni eru cinnig ólíkar milli mála. Ýmsir þættir hafa áhrif á það hvaða aðgerða er þörf, svo sem stærð málsamfélagsins og hversu flókið tungumálið er. Á vegum META-NET, sem er öndvegisnet fjármagnad af Evrópusambandinu, hefur verið lagt mat á núverandi stöðu í málföngum og máltaekni (sjá bls. 73). Þessi greining tók til hinna 23 opinberu mála Evrópusambandsins auk annarra mikilvægra þjóðtungna og svæðisbundinna tungumála í álfunni. Niðurstöður þessarar greiningar benda til að í öllum málunum skorti rannsóknir á mikilvægum sviðum. Nákvæmari greining sérfræðinga og mat á núverandi stöðu mun hjálpa til við að hámarka árangur viðbótarrannsókna og lágmarka áhættu.

META-NET tengir saman 54 rannsóknarsetur í 33 löndum (í nóvember 2011, sjá bls. 69). Þau vinna með hagsmunaaðilum úr viðskiptalífinu (hugbúnaðarfyrirtækjum, tæknifyrtækjum og notendum), frá opinberum stofnunum, rannsóknarstofnunum, sjálfstæðum félagasamtökum, fulltrúum málsamfélaga og evrópskum háskólum. Í samstarfi við þessa aðila vinnur META-NET að þróun heildstæðrar tæknisýnar og útfærðri rannsóknarstefnu handa margmála Evrópu árið 2020.

This white paper is part of a series that promotes knowledge about language technology and its potential. It addresses journalists, politicians, language communities, educators and others. The availability and use of language technology in Europe varies between languages. Consequently, the actions that are required to further support research and development of language technologies also differs. The required actions depend on many factors, such as the complexity of a given language and the size of its community.

META-NET, a Network of Excellence funded by the European Commission, has conducted an analysis of current language resources and technologies in this white paper series (p. 73). The analysis focused on the 23 official European languages as well as other important national and regional languages in Europe. The results of this analysis suggest that there are tremendous deficits in technology support and significant research gaps for each language. The given detailed expert analysis and assessment of the current situation will help maximise the impact of additional research.

As of November 2011, META-NET consists of 54 research centres from 33 European countries (p. 69). META-NET is working with stakeholders from economy (software companies, technology providers, users), government agencies, research organisations, non-governmental organisations, language communities and European universities. Together with these communities, META-NET is creating a common technology vision and strategic research agenda for multilingual Europe 2020.

Höfundar þessa rits þakka höfundum hvítbókar um þýsku fyrir leyfi til að endurnýta almenna kafla úr verki þeirra [1].

Gerð þessarar hvítbókar var kostuð af Sjöundi ramma-áætlun Evrópusambandsins og Stefnumótunaráætlun Evrópusambandsins í upplýsinga- og samskiptatækni samkvæmt samningum við T4ME (styrksamningur 249119), CESAR (styrksamningur 271022), METANET4U (styrksamningur 270893) og META-NORD (styrksamningur 270899).

The authors of this document are grateful to the authors of the White Paper on German for permission to re-use selected language-independent materials from their document [1].

The development of this white paper has been funded by the Seventh Framework Programme and the ICT Policy Support Programme of the European Commission under the contracts T4ME (Grant Agreement 249119), CESAR (Grant Agreement 271022), METANET4U (Grant Agreement 270893) and META-NORD (Grant Agreement 270899).



EFNISYFIRLIT CONTENTS

ÍSLENSK TUNGA Á STAFRÆNNI ÖLD

1	Yfirlit	1
2	Hættur sem steðja að tungumálinu: Ögrun fyrir máltaekni	4
2.1	Tungumálaþróskuldar standa í vegi fyrir evrópsku upplýsingasamfélagi	5
2.2	Tungumál okkar í hættu	5
2.3	Máltaekni er grundvallarstuðningstækni	6
2.4	Tækifæri máltaekninnar	6
2.5	Ögranir sem máltaekni stendur frammí fyrir	7
2.6	Máltaka manna og véla	7
3	Íslenska í evrópsku upplýsingasamfélagi	9
3.1	Almenn atriði	9
3.2	Sérkenni íslenskrar tungu	10
3.3	Nýleg þróun	11
3.4	Íslensk málrækt	11
3.5	Íslenska í menntakerfinu	12
3.6	Alþjóðlegir þættir	13
3.7	Íslenska á netinu	14
4	Máltaekni fyrir íslensku	15
4.1	Högun máltaeknibúnaðar	15
4.2	Helstu verksvið	16
4.3	Önnur verksvið	23
4.4	Námsleiðir	24
4.5	Innlend verkefni og viðfangsefni	25
4.6	Aðgengi að máltaeknitólum og málföngum	26
4.7	Samanburður tungumála	26
4.8	Niðurstöður	28
5	Um META-NET	31

THE ICELANDIC LANGUAGE IN THE DIGITAL AGE

1 Executive Summary	33
2 Languages at Risk: a Challenge for Language Technology	36
2.1 Language Borders Hold back the European Information Society	37
2.2 Our Languages at Risk	37
2.3 Language Technology is a Key Enabling Technology	38
2.4 Opportunities for Language Technology	38
2.5 Challenges Facing Language Technology	39
2.6 Language Acquisition in Humans and Machines	39
3 The Icelandic Language in the European Information Society	41
3.1 General Facts	41
3.2 Particularities of the Icelandic Language	42
3.3 Recent Developments	43
3.4 Official Language Protection in Iceland	44
3.5 Language in Education	45
3.6 International Aspects	45
3.7 Icelandic on the Internet	46
4 Language Technology Support for Icelandic	48
4.1 Application Architectures	48
4.2 Core Application Areas	49
4.3 Other Application Areas	56
4.4 Educational Programmes	57
4.5 National Projects and Initiatives	58
4.6 Availability of Tools and Resources	59
4.7 Cross-language comparison	59
4.8 Conclusions	61
5 About META-NET	64
A Tilvísanir – References	65
B META-NET þáttakendur – META-NET Members	69
C Hvítbókaröð META-NET – The META-NET White Paper Series	73

YFIRLIT

Upplýsingatæknin hefur breytt hversdagslífi okkar. Við notum tölvur til að skrifa og vinna með texta, reikna, leita upplýsinga, og sífellt meira einnig til að lesa, hlusta á tónlist, skoða myndir og horfa á kvíkmyndir. Við göngum með snjallsíma og spjaldtölvur á okkur og notum til að hringja, senda tölvupóst, afla okkur upplýsinga og stytta okkur stundir, hvar sem við erum stödd. Hvaða áhrif hefur þessi viðtæka stafræna bylting í upplýsingum, þekkingu og hversdagssamskiptum á tungumál okkar? Mun það breytast eða jafnvel deyja út? Hvaða möguleika hefur íslenska á að lifa af?

Mörg hinna 6.000 tungumála heimsins munu ekki lifa af í hinu hnattræna stafræna upplýsingasamfélagi. Talið er að a.m.k. 2.000 tungumál deyi út á næstu áratugum. Önnur munu lifa af inni á heimilum og í daglegum samskiptum, en ekki verða notuð í viðskiptalífinu eða vísindum og fræðum. Staða tungumálsins ræðst ekki bara af fjölda málnotenda, eða fjölda bóka, kvíkmynda og sjónvarpsstöðva þar sem málið er notað, heldur einnig af hlutverki málsins í hinum stafræna upplýsingaheimi og innan hugbúnaðargeirans.

Á þessu sviði er íslenska ekki sérlega vel stödd. Í lok 20. aldar var íslensk máltaekni nánast ekki til. Við áttum allgóðan stafrýni (*Púka*), ófullkominn talgervil, og þar með upp talið. Enginn íslenskur háskóli bauð upp á námsleiðir eða jafnvel einstök námskeið í máltaekni eða tölvumálvísdum, engar rannsóknir voru stundaðar á þessu sviði, og engin íslensk hugbúnaðarfyrirtæki unnu að máltaekniverkefnum [2].

Þetta fór að breytast eftir að sérstakur starfshópur skilaði skýrslu um máltaekni til menntamálaráðherra árið

1999 [3]. Í þessari skýrslu voru settar fram tillögur um ýmsar aðgerðir til að koma íslenskri máltaekni á laggirnar. Árið 2000 setti ríkisstjórnin af stað sérstaka máltaekniáætlun með það að markmiði að styðja stofnanir og fyrirtæki til að koma upp undirstöðumálföngum – gagnasöfnum og hugbúnaði – fyrir íslenska máltaekni. Þetta frumkvæði gat af sér ýmis verkefni sem hafa lagt grundvöll að íslenskri máltaekni [2].

Eftir að máltaekniáætluninni lauk árið 2004 ákváðu fræðimenn frá þremur stofnunum (Háskóla Íslands, Háskólanum í Reykjavík og Stofnun Árna Magnússonar í íslenskum fræðum) að taka höndum saman og mynda samstarfsvertvang sem nefnist Máltaeknisetur (Icelandic Centre for Language Technology, ICLT) [4] til að fylgja viðfangsefnum áætlunarinnar eftir. Frá 2005 hafa fræðimenn Máltaeknisseturs ýtt úr vör ýmsum verkefnum sem hafa fengið styrki frá Rannsóknasjóði og Tækniþróunarssjóði.

Þrátt fyrir að talsvert hafi áunnist sýnir þessi skýrsla að það er einungis á sviði grundvallarbúnaðar og málfangar svo sem málfræðimörkunar, setningafræðilegar þáttunar, málheilda og trjábanka sem staða íslenskunnar er viðunandi. Á flóknari sviðum eins og í merkingargreiningu setninga og texta, samræðukerfum, upplýsingaheimt, málmyndun, samantekt texta, merkingargreindum málheildum o.s.frv., er ekkert til fyrir íslensku. Því er ljóst að mikil starf er óunnið við að tryggja framtíð íslenskunnar sem fullgilds þátttakanda í evrópsku upplýsingasamfélagi nútímans – og framtíðarinnar.

Upplýsinga- og samskiptatæknin er nú á þróskuldi nýrrar að byltingar. Í kjölfar einkatölva, netvæðingar, marg-