İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

AKRABA VE BİTİŞKEN DİLLER ARASINDA BİLGİSAYARLI ÇEVİRİ İÇİN KARMA BİR MODEL

DOKTORA TEZİ

Y. Müh. Ahmet Cüneyd TANTUĞ

Anabilim Dalı: Bilgisayar Mühendisliği

Programı: Bilgisayar Mühendisliği

Tez Danışmanı: Prof. Dr. Eşref ADALI

OCAK 2007

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

AKRABA VE BİTİŞKEN DİLLER ARASINDA BİLGİSAYARLI ÇEVİRİ İÇİN KARMA BİR MODEL

DOKTORA TEZİ

Y. Müh. Ahmet Cüneyd TANTUĞ

Anabilim Dalı: Bilgisayar Mühendisliği

Programı: Bilgisayar Mühendisliği

Tez Danışmanı: Prof. Dr. Eşref ADALI

OCAK 2007

ÖN SÖZ

İÇİNDEKİLER

KISALTMALAR

DDİ	:	Doğal Dil İşleme
BÇ	:	Bilgisayarlı Çeviri
HMM	:	Hidden Markov Model
MM	:	Markov Model (Visible Markov Model)
ASCII	:	American Standard Code for Information Interchange
İDM	:	İstatistiksel Dil Modeli
ÇG	:	Çekim grubu (Inflectional Group)
SDD	:	Sonlu Durumlu Dönüştürücü
SDT	:	Sonlu Durumlu Tanıyıcı

TABLO LİSTESİ

ŞEKİL LİSTESİ

ÖZET

Diller arası çeviride bilgisayarların kullanılması fikrinin başlangıcı 1950'lerin ilk yıllarına kadar uzanmaktadır. O tarihten günümüze kadar teknolojik alanda yaşanan devasa gelişmelere, konunun çekiciliği cazibesi yüzünden akademik ve ticari çevrelerde bu konu ile uğraşan araştırmacı sayısının fazlalığına, siyasi, ekonomik ve sosyal nedenlerden dolayı devletler tarafından desteklenmesine ve yüklü miktarlarda bütçeler ayrılmasına karşın tahsis edilmesine rağmen, günümüzde dahi bilgisayarlı çeviri (BÇ) tam anlamıyla hayata geçirilememiştir. Elbette ki bütün bu emeklerin sonucunda BÇ alanında belirli bir noktaya gelinmiştir. Ancak hedeflenen, şu üç özelliği bir arada sağlayan sistemlerin ortaya çıkmasıdır:

1. İnsan etkisine gerek duymadan tam otomatik çeviri yapabilme yeteneği,
2. Belirli bir konuya bağlı olmaksızın genel amaçlı metinler üzerinde çeviri yapabilme yeteneği,
3. Üretilen sonuçların çıktıların, insanların hazırladığı çeviriler gibi anlaşılır olması ve aslına uygun olan anlamı taşıması

BÇ'nin zorluğunun en temel nedeni, diller arasındaki büyük farklılıklardır. Aynı dil ailesinde bulunan diller arasında çeviri yapılırken bile karşılaşılan zorluklar, tamamen farklı dil ailelerinden gelen ve bütünü ile farklı dilbilgisel yapıya sahip olan diller arası çevirilerde yaşanan zorluklarının boyutunu göz önüne sermektedir. Günümüzde BÇ çalışmalarının çoğu İngilizce, Almanca, Fransızca, Çince ve Arapça gibi yaygın kullanıma sahip diller arasında gerçeklenmektedir. Son yıllarda ise Çince'den İngilizce'ye ve Arapça'dan İngilizce'ye çeviri çalışmaları konuları, ABD'nin sağladığı desteklerle yoğunluk kazanmıştır.

Yöntembilim açısından incelendiğinde, BÇ alanında iki farklı dönem olduğu görülmektedir: 1950'lerden 1990'ların başına kadar geliştirilen sistemler çoğunlukla çeşitli dilbilgisel düzeylerde (biçimbirimsel, sözdizimsel, anlamsal) çalışan kural tabanlı yöntemler kullanılarak gerçeklenmişlerdi. Bunlar örnek olarak Meteo, Systran, METAL, Logos gibi sistemler sayılabilr. 1990'lı yıllardan başlayarak, ses

işleme ve tanıma gibi alanlarda başarısı kanıtlanmış olan istatistiksel yöntemlerin BÇ alanında da denenmesi yoluna gidildi gidilmiştir. IBM'in önderliğini yaptığı başını çektiği bu çalışmalar sonucunda elde edilen başarılar, kural tabanlı sistemlerde tıkanan ve ileri gidemeyen çalışmaların büyük bir bölümünü istatistiksel BÇ'ye yönelttı yöneltmiştir. Yine Gene son 20 yılda ortaya çıkan ve çevrilecek metni bir veritabanındaki veri tabanındaki örneklere benzeterek çıktı üreten üçüncü yöntemde, örnek tabanlı BÇ yöntemi kullanılmaya başlandı başlanılmıştır. Günümüzde de çalışmaların çoğunluğu istatistiksel BÇ ve örnek tabanlı BÇ ekseninde gerçekleştirilmektedir.

BÇ önünde en büyük engel olan dillerin arasındaki farklılıklar, akraba ya da yakın dil çiftleri için daha az görüleceğinden, bu diller arasında BÇ'nin daha kolay olacağı sezgisel olarak anlaşılmaktadır. Hatta sözdizimsel açıdan aynı olan birçok dil çifti için sözcük temelinde bazında yapılacak doğrudan aktarım yöntemlerinin bile başarılı olabileceği söylenebilir. Nitekim 2000'li yılların başından itibaren yayınlanan bazı çalışmalarda, benzer ya da yakın akraba dil çiftleri arasında BÇ yapmanın, birbirlerinden çok farklı dil çiftleri arasında BÇ yapmaktan daha kolay olması gerektiği ileri sürülmüş ve bu fikirden hareketle çeşitli uygulamalar gerçekleştirilmiştir. Çekçe ve İspanyolca olmak üzere iki merkezde toplanan çalışmalarda Çekçe-Slovakça, Çekçe-Lehçe, Çekçe-Litvanyaca, İspanyolca-Katalanca gibi birbirlerine yakın diller arasında BÇ ile başarılı sonuçlar elde edilmiştir. Anılan bu dil çiftleri birbirlerine çok benzemektedirler (Litvanyaca hariç). Hatta, buradaki hedef diller, kaynak dil ile neredeyse tamamen aynı sözdizimsel yapıya sahiptir. Bütün çeviriler, sözcük sıraları değiştirilmeden sözcük temelinde bazında gerçeklenmektedir. Üstelik eşadlı (homonym) sözcükler dahi hedef dile çevrildiği zaman genellikle aynı biçimde eşadlı olarak kaldığından, çeviri sözlükleri bire bir çıktı üretecek şekilde tasarlanmıştır.

Yapılan çalışmaların diğer benzer ya da akraba diller için genişletilmesi noktasında birtakım sorunlar ortaya çıkmaktadır. Bunlardan en önemlisi, sözcük seçiminde anlamsal farklılıkların olduğu dil çiftlerinde görülmektdir. Her ne kadar seçilen dil çifti yakın olsa bile, kaynak dildeki her sözcüğün hedef dilde sadece bir karşılığının olması her dil çifti için geçerli değildir. Seçilecek hedef dil karşılıklarının, bağlama bağlı olarak belirlenmesinin gerekli olduğu durumlarda bu sistemler yetersiz kalacaklardır. Bir başka sorun ise, örneğin Türkçe gibi bitişken dillerin sahip olduğu

karmaşık biçimbirimsel yapıların aktarılması noktasında ortaya çıkmaktadır. Söz konusu sistemler, kaynak dil için biçimbirimsel çözümleyici, sözcük türü etiketleyici ve hedef dil için de biçimbirimsel üretici araçlara gerek duymaktadır.

Tez çalışması kapsamında, akraba ve bitişken olan dil çiftleri arasında BÇ için bazı çeviri modelleri önerilmiş, bu modellerle Türk Dil ailesi için BÇ konusu incelenmiştir. Önerilen çeviri modelleri, kural tabanlı çeviri ile istatistiksel çeviri yöntemlerinin birleşiminden oluşan karma (hibrid) modellerdir. Önerdiğimiz modellerin matematiksel tanımı verildikten sonra modeller, Türk Dil ailesi içerisinde BÇ açısından değerlendirilmiştir. Ancak önerilen çeviri modelleri Türk Dillerine özgü olmayıp, bitişken ve akraba ya da yakın iki dil çifti arasında BÇ için kullanılabilir niteliktedir. Modelin uygulaması için, Türkmence'den Türkçe'ye bir aktarım sistemi gerçeklenmiş ve sonuçları değerlendirilmiştir.

Türk dilleri, Azerice, Türkmence, Özbekçe, Tatarca, Kazakça, Kırgızca, Uygurca vb. gibi dillerden oluşan, toplamda yaklaşık 180 milyon insan tarafından geniş bir coğrafyada kullanılmakta olan dillerden oluşmaktadır. Bu dillerin benzerlik ve farklılıkları değişmekle beraber, çoğu Türk dili, sözdizimsel açıdan hemen hemen aynıdır. Bütün Türk dilleri üretken türetme ve çekim özelliği olayları içerdiğinden, diğer dillere oranla daha karmaşık biçimbirimsel yapılara sahiptirler. Türk Dilleri üzerinde çalışmanın en büyük zorluğu, doğal dil işleme (DDİ) açısından gerekli araçların henüz oluşturulmamış olmasından kaynaklanmıştır. Türkçe, DDİ alanında günümüze kadar yapılan çalışmalar sonucunda ortaya konulan çeşitli araçlar ve veri kaynakları ile diğer Türk Dillerinden bu konuda ayrılmaktadır.

Önerilen modellerin başarımlarını ölçmek ve gerçekleştirmede ortaya çıkan pratik sorunları görmek için sonlu durumlu dönüştürücüler, Hidden Markov Modelleri (HMM), Viterbi algoritması gibi yöntemleri kullanan bir uygulama gerçekleştirilmiştir. Uygulama sonucunda önerilen modellerin başarıları karşılaştırılmış, sistemin zayıf ve kuvvetli yönleri irdelenmiştir. Gerçeklenen uygulama, sadece Türkmence - Türkçe dil çifti için değil, önerilen modelleri kullanarak tüm Türk Dilleri arasında çeviri yapılabilmesini sağlayacak çerçeve bir sistem geliştirilmiştir.

Özet olarak tez çalışması kapsamında bitişken yapıya sahip akraba ya da benzer diller arasında BÇ için, kural tabanlı ve istatistiksel tabanlı bileşenlerden oluşan

karma çeviri modelleri tanımlanmış, bu modeller Türk Dil Ailesi'ndeki diller için incelenmiş, Türkmence'den Türkçe'ye bir aktarım sistemi gerçeklenerek önerilen modellerin gerçekten başarılı çeviri yapabildiği gösterilmiştir.

SUMMARY

The idea of using computers for natural language translation has a very long history which goes back to the beginnings of 1950s. Unfortunately, the ideal machine translation (MT) could not be achieved truly despite of the huge development in technology, the enormous amount of researchers all over the world and tons of projects mainly supported by governments with very high budgets. An ideal MT should has these three properties:

1. Fully Automatic
2. Ability to process on unrestricted texts (topic may vary)
3. High Quality Outputs: which means the results of the system can be easily understood by human and should preserve the meaning in the original sentence

MT is a hard task because of the differences between languages like typological, morphological, structural and lexical divergences. Even MT between languages belonging the same language family suffer from these differences.

Most of the work in the MT field is concentrated around the major languages like English, German, French, Chinese and Arabic. Recently, USA Government supports the efforts of MT from Arabic or Chinese to English.

From the point of view of the methodologies used, MT history can be separated into two sections. The first part took place between the very early of 1950s to the late 1980s. During this period of time, MT was primarily performed by using rule based transfers of some representation levels like morphological, syntactical or semantic representations. Some of the famous systems of this period are Meteo, Systran, METAL and Logos. In the late 1980s, statistical methods took place in MT arena. Statistical methods were proven techniques in many of the other fields like speech recognition and pattern processing. Statistical MT (SMT), led by IBM, encouraged lots of researchers to shift their motivation from complex and hard to improve rule

based systems to brand-new SMT based methods. Meanwhile, a third approach for MT was emerged: Example Based MT (EBMT). This approach is based on translation by making an analogy between the input and previously seen training sentence pairs. Today, most of the work in MT field is exercised around SMT and EBMT methods.

Intuitively, translation between related languages seems to be accomplished easier than the translation between distinct language pairs. Besides, it can be said that word-by-word direct transfer of source language (SL) to the target language (TL) can produce successful translations if both the source and target language has the same or similar word order. MT between related languages is recently a new topic where the first studies are carried out mostly after 2000. Studies on this topic have been done around these two languages: Czech and Spanish. MT systems between very close language pairs like Czech-Slovak, Czech-Polish, Czech-Lithuanian and Spanish-Catalan are implemented within the context of direct transfer fashion. The results of these MT systems showed that successful translations can be generated by employing relatively less effort. All of the language pairs above are very close languages (except Czech-Lithuanian which is only close) and the syntactical structures of both of the languages are almost the same. Even homonyms preserve their homonymy after translation, so it is usually enough to transfer the root words in one-to-one manner.

While expanding these studies to other cognate language pairs, some serious problems can emerge. The most important problem is the lexical ambiguity problem; which means existence of multiple TL words for one SL word. Generally, the selection of the right TL equivalent requires the usage of context. However the systems above do not process polysemous words because of the assumption stating that there is always one-to-one mapping between SL and TL words. Another problem can be observed in MT between close and agglutinative language pairs which require a complex transformation of both root words and the morphology.

In this work, we present some new MT models for translation between agglutinative and related languages. The proposed MT models are hybrid models which have both statistical and rule-based components. The mathematical explanations of these models are presented in this thesis. We have investigated the usability of these models for Turkic Languages and have implemented a real MT system from

Turkmen Language to Turkish in order to evaluate our models. Although most of the examples and the implementation are on Turkic Languages, the proposed models are not designed only for Turkic Languages. In fact, these models are generic models that can be applicable to all other related language pairs that have agglutinative morphologies (like Finnish-Estonian).

Turkic Language family includes cognate languages like Turkish, Azeri Language, Turkmen Language, Uzbek Language, Uighur Language, Kazakh Language and etc. These languages are used more than 180 million people especially in Central Asia and West Asia. All of these languages share lots of akin properties as well as being agglutinative and having the same word order (SOV). Having productive inflectional and derivational morphology is the major common property of Turkic Languages. The most serious problem for MT between Turkic Languages is the lack of NLP related tools such as morphological analyzers, morphological disambiguators and training corpus for most of these languages (except Turkish). At this point, it must be asserted that these languages are not mutually intelligible despite of these similarities. Otherwise there will be no need for translation.

The implementation is built by using mostly finite state methods. In the statistical component we have used Hidden Markov Models (HMM) and a modified Viterbi Algorithm for the decoding process. The test translations of our MT implementation are used to evaluate the performances of the proposed models. The implementation is designed as a framework which can be used for almost all Turkic Languages.

In summary, we present a hybrid translation model for MT between related and agglutinative language pairs. This model is based on both statistical and rule-based transfer approaches. MT between Turkic Languages is investigated and a test implementation is performed from Turkmen to Turkish. As a result, it can be said that we have succeed in generating satisfactory translations and we get remarkable *BLEU* scores with our simple but efficient implementation although the *BLEU* evaluation method underestimates the quality of translations in agglutinative and word order free langaues.

1. GİRİŞ

"Dil, insanların meramlarını anlatmak için kullandıkları bir sesli işaretler dizisidir." [1]. En kısa ve temel tanımlarından biri yukarıdaki gibi verilmiş olan dil, insanların birbirleri ile anlaşmalarını sağlayan en güçlü araçtır. Ancak dili oluşturan bu sesli işaretler dizisi, dünya üzerinde farklı coğrafyalarda çok değişik biçimlerde kullanılmaktadır. Dillerdeki bu farklılık, dilin bilgisayarla işlenmesi noktasında genel geçer kuralların ve yöntemlerin kullanılmasını sınırlamış, her dilin kendine özgü sorunlarının çözümü için özel çaba harcanmasını ve yeni yöntemlerin geliştirilmesini zorunlu kılmıştır. Türkçemiz üzerine şimdiye dek yapılan çalışmalar, İngilizce, Fransızca, Almanca gibi diğer başlıca (hatta göreceli olarak çok daha az insanın kullandığı Danimarkaca, Hollandaca gibi diğer) diller üzerine yapılan çalışmalar yanında sayısal olarak oldukça yetersiz kalmaktadır. Üstelik Türkçe, yapısal ve dilbilgisel zenginlikleri ve kendine has farklılıkları ile diğer dillerden çok daha değişik bir konumdadır. Bu tez ile Türkçe ve diğer Türk dilleri üzerine yapılan çalışmalara katkıda bulunulması hedeflenmiştir.

1.1. Bilgisayarla Dil İşleme ve Bilgisayarlı Çeviri

Yapay zeka ve dilbilimi disiplinlerinin bir alt dalı olan doğal dil işleme konusu, temel amaç olarak insanların iletişim amaçlı kullandıkları dilleri (doğal diller) otomatik olarak çözümlemeyi, anlamayı, yorumlamayı ve üretmeyi gütmektedir.

Günümüzde insan-bilgisayar iletişimi (human-computer interaction), çoğunlukla insanların bilgisayarları çeşitli araçlarla (tuş takımı, fare gibi) yönetmeleri komuta etmesi ile sağlanmaktadır. Doğal dil işleme araştırmalarının amacı insanların bilgisayarlar ve genel olarak makinelerle iletişimlerini çok daha doğal yollardan yani konuşarak ya da yazarak gerçekleştirebilmelerini sağlamaktır. Bu kapsamda konuşma tanıma, konuşma üretme, yazılı metinden anlam çıkarma, veri tabanında bulunan bilgileri tümceye dökme, bilgisayarlı çeviri yapma, soru-cevap sistemleri geliştirme, özet çıkartma, yazım hatası düzeltme gibi bir çok uygulama hayat bulmaktadır.

Doğal dil işleme yöntemleri genellikle çeşitli bilgi düzeylerinde çalışırlar:

1. Sesbilim (Phonetics & Phonology)

   Konuşmaları, sesleri ve harflerin okunuşlarını inceler.

2. Biçimbirim (Morphology)

   Sözcüklerin yapı taşlarını (anlamlı alt birimlerini) inceler.

3. Sözdizimi Düzeyi (Syntax)

   Dilbilgisi yapısını ve tümcenin tümcenin sözcükleri arasındaki ilişkileri inceler.

4. Anlambilim (Semantics)

   Dildeki her türlü anlam konusunu inceler.

5. Bağlam Düzeyi (Pragmatics)

   Farklı bağlamlarda dilin kullanımının getirdiği farklılıkları inceler.

6. Konuşma Düzeyi (Discourse)

   Birbirini takip eden konuşmaları (diyalog, monolog gibi) inceler.

Hiç kuşkusuz söylenebilir ki, doğal dil işleme alanındaki bütün uygulamaların en büyük sıkıntısı dillerdeki karmaşıklık ve belirsizliktir. İnsanlar arasında dahi iletişim güçlüklerine ve yanlış anlaşılmalara yol açan dildeki bu belirsizlikler ve karışıklıklar, bilgisayar ortamında doğal dillerin modellenmesinin önündeki en büyük engeli oluşturmaktadır.

Bilgisayarlı çeviri (BÇ), doğal dil işlemenin en güncel popüler konuları arasında gelmektedir. Her geçen gün daha da küreselleşen dünyada, farklı dilleri konuşan insanların iletişim kurmaları, geçmiş yıllara göre çok daha önem kazanmıştır. Bu yüzden dil engelini kaldıracak her türlü çalışmaya gereksinim her zamankinden fazladır. Günümüzde, bilgisayarlı çeviri alanında başarılı sayılabilecek sonuçlar çıktılar üretebilen sistemler bulunmakla beraber genel amaçlı kullanılabilecek yüksek başarımlı BÇ sistemleri henüz geliştirilememiştir. Ayrıca geliştirilen sistemler az kısıtlı sayıda diller üzerinde gerçeklendiğinden bir çok dil çifti arasında BÇ sistemi henüz bulunmamaktadır. BÇ tarihi incelendiğinde, 1980'lerin sonlarına kadar insan emeği ile oluşturulan kural tabanlı sistemlerin kullanıldığı görülürken, 1990'ların başlarından itibaren elektronik ortamdaki metinlerin miktarlarının ve kullanılabilirliğinin artması ile istatistiksel ve örnek tabanlı yöntemlerin yaygınlaştığı

görülür. Ancak bütün çalışmalara ve teknolojik gelişmelere karşın rağmen arzulanan BÇ sistemlerinin geliştirilmesi şu an için gerçeklenebilir yapılabilir görünmemektedir.

1.2. Çalışmanın Amacı

Bu tez çalışmasının amacı, bilgisayarlı çeviri konusunda bilinen eski tekniklerle son yıllarda ortaya çıkan bilgi ve istatistik tabanlı yeni teknikleri beraber kullanarak, akraba Türk dilleri arasında çeviri yapabilecek bir çeviri modelini geliştirmektir. Tarihsel, yapısal ve dilbilgisel açıdan farklılıklar gösteren dil çiftleri arasında çevirinin yapılabilirliği halen uzak olmasına karşın, akraba dil çiftleri arasında gözlenen yapısal ve dilbilgisel benzerliklerin getirdiği kolaylıklar sayesinde yakın dil çiftleri arasında bilgisayarlı çeviri sistemlerinin geliştirilmesi daha akla yakın gelmektedir.

Türkçe, Azerice, Türkmence, Özbekçe, Kırgızca, Kazakça gibi Türk dilleri, ortak tarih ve coğrafya hamuru içerisinde oluştukları için bugün dahi İngilizce, Almanca gibi batı kökenli diğer dillerle kıyaslanmayacak derecede birbirlerine benzemektedirler. Her ne kadar uzun yıllar boyu süren Sovyet yönetiminin getirdiği olumsuz etkiler bu diller üzerinde önemli tahribatlara yol açmış olsa da Türk dilleri arasındaki yakınlıklar ve benzerlikler belirli ölçeklerde günümüze kadar korunmuştur.

Bu çalışmada, Türk dillerinin özellikleri ile bilinen bilgisayarlı çeviri yöntemleri incelenmiş, Türk dilleri arasında bilgisayarlı çeviri yapılabilmesi için yeni matematiksel modeller önerilmiştir. Bu modellere göre Türkmence-Türkçe dilleri arasında çeviri yapabilecek bir sistem gerçeklenerek uygulamada ortaya çıkan aksaklıklar irdelenmiş, bu sorunlara yeni çözüm yöntemleri önerilerek bu yöntemlerinin etkileri araştırılmıştır.

1.3. Önceki Çalışmalar

Bilgisayarların, farklı diller arasında çeviri yaptırmak amacıyla kullanılması fikri yaklaşık 50 yıllık bir geçmişe sahiptir. Bu süre boyunca dillerin doğasındaki karmaşıklığı ve değişik diller arasındaki farklılıkları gidererek çeviri yapabilmek için çeşitli bilgi seviyelerinde birçok yöntem denenmiştir. Günümüzde iki dil arasında,

konudan bağımsız olarak yüksek kaliteli çevirileri otomatik üretebilen sistemler, henüz geliştirilememiştir. Ancak geliştirilen sistemler içerisinde, aralarında derin ayrılıklar içermeyen dil çiftleri arasında çeviri yapan sistemlerin sonuçlarının çıktılarının, yapısal olarak çok farklı diğer dil çiftleri arası çevirilerden daha kaliteli olduğu görülmektedir. Örneğin aynı dil ailesinde sınıflandırılan İngilizce ve Almanca arasında gerçeklenen çeviri sistemlerinin başarısı, farklı dil ailelerinde olan İngilizce ve Japonca arasındaki bilgisayarlı çeviri sistemlerinin başarısından daha yüksektir [2]. Bu sonuç tespit diller arasındaki benzerlik oranı arttıkça bilgisayarlı çeviri sistemlerinin geliştirilmesinin daha kolay olacağı ve yüksek başarımlı çevirilerin elde edilebileceği izlenimini uyandırmaktadır.

Benzer diller arasında yapılan ilk bilgisayarlı çeviri çalışması, Çekçe ile Rusça arasında bilgisayarlı çeviri sistemi olan RUSLAN sistemidir [3]. Eski Doğu Bloku ülkelerinde, anaçatı (mainframe) işletim sistemleri ile ilgili her türlü belgenin dokümanın Rusça'ya çevrilmesinin zorunluluğu bulunduğundan, 1985'te geliştirilmeye başlanmış olan bu sistem 1990'larda ödenek yetersizliğinden durdurulmuştur. Gerçeklenen sistem sadece Çekçe'den Rusça'ya çeviri yapabilmekteydi.

Bu sistemde, kural tabanlı biçimbirimsel çözümleyici, çeviri ve biçimbirimsel birleştirici modülleri bulunmakla beraber, sözdizimsel ayrıştırıcı (Çekçe için) ve birleştirici (Rusça için) modülleri de bulunmaktadır.

Çalışmanın sonuçlarında, hedef dilde oluşturulan tümcelerin %40'nın doğru olarak çevrildiği, %40'nın bir insan operatör tarafından düzeltilmesi gereken ufak hatalar içerdiğini, geri kalan %20'lik bölümün ise tamamen baştan çevrilmesi gerektiği bildirilmiştir. Başarısız çevirmelerin nedenleri olarak, çeviri sözlüğünün küçük olması (10.000 sözcük) ve bu sözlükte Çekçe'nin, kural tabanlı bir çözümleyici ile çözümlenemeyen bir çok sözdizimsel durumun varlığı gösterilmiştir.

Çekçe üzerine yapılan bir başka çalışma ile RUSLAN sistemine benzer bir çeviri sistemi, birbilerine çok benzeyen iki dil, Çekçe ve Slovakça arasında geliştirilmiştir [4]. ČESĬLKO adı verilen bu çalışmada, kaynak ve hedef diller birbirlerine çok benzediği için daha basit yöntemler kullanılmıştır. Bu yöntemlerin temelinde sözcük bazında çeviri yapılmaktadır. Aşağıda bu sistemi oluşturan bileşenler tanıtılmıştır:

1. Çekçe biçimbirimsel çözümleme

2. Çekçe biçimbirimsel belirsizliğin giderilmesi
3. Konuya özel aktarım sözlüğü (tek ve birden fazla sözcükten oluşan girdiler)
4. Genel amaçlı aktarım sözlüğü
5. Slovakça biçimbirimsel üretim

Çekçenin biçimbirimsel çözümlemesi için, başarısı %99 olarak belirtilen bir çözümleyici (700.000 kök girdili) kullanılmıştır. Sözcük türü etikelemesi için istatistiksel yöntemlere dayanan bir yöntem kullanılmıştır. Bu yöntemde, gazetelerin haberlerinden oluşan bir eğitim kümesi üzerinde eğitilen ve başarı oranının %98 olduğu belirtilen "log-lineer" olasılık dağılımı modeli kullanılmıştır. Sözcüklerin ve biçimbirimsel bilgilerin aktarılması için çift dilli aktarım sözlükleri kullanılmıştır. Eşsesli sözcükler çevrildikten sonra da gene eşseli kaldıkları için iki dil arası çeviri de herhangi bir anlam belirsizliği oluşmadığı belirtildiğinden, aktarım sözlüğü, birebir 1:1 aktarım yapacak şekilde geliştirilmiştir.

ČESĬLKO sistemin başarımı Çekçe-Slovakça arasında %90 civarında rapor edilmiştir. Daha sonra bu çalışma diğer Slav dilleri için de genişletilmiş, ilk olarak yine gene Çekçe'ye benzer bir dil olan ve Hint-Avrupa dil ailesinin Slav kolunun batı grubunda Çekçe ile aynı yerde sınıflandırılan Lehçe hedef dil olarak seçilmiştir. Bir sonraki adımda ise Çekçe ile diğerlerine göre daha az benzerlik gösteren ancak yine gene Hint-Avrupa dil ailesinin Baltık kolunda yer alan sınıflandırılan Litvanyaca hedef dil olarak kullanılmıştır [5]. Çalışma sonucunda Çekçe-Lehçe başarımı %71, Çekçe-Litvanyaca başarımı ise %69 olarak belirtilmiştir. Litvanyaca dilinin farklı yapısından dolayı, çeviri sistemine çok kapsamlı olmayan bir Çekçe sözdizimsel çözümleyici eklenmiştir. Yapılan çalışmaların başarım ölçütü, TRADOS isimli, bilgisayar destekli çeviri için geliştirilmiş bir yazılımın eşleştirme bileşeni ile ölçülmüştür. Çevirmenleri, sistem çıktılarını düzelterek ya da olduğu gibi kullanarak referans çeviriler üretmiş, üretilen bu referans ile sistem çıktısı çevirilerin benzerliği, TRADOS yazılımının eşleştirme bileşeni yardımı ile hesaplanmıştır. ČESĬLKO sistemi çatısında yapılan bir başka çalışma da çok az kişinin (20.000'den az) kullandığı Sırpçanın bir türü (Lower Serbian) üzerinde gerçekleştirilmiş ve aynı ölçüm yöntemi ile %93 başarı elde edildiği ileri sürülmüştür [6].

Benzer diller arasında gerçeklenen bir diğer çalışma ise Hint-Avrupa dil ailesinin Romance kolunun Ibero-Romance alt grubunda beraber sınıflandırılan İspanyolca ile

Katalanca dilleri arasında yapılmıştır [7]. Söz konusu sistemde sekiz temel bileşen bulunmaktadır:

1. Biçim Ayıklayıcı (deformatter) : RTF ve HTML etiketlerini ayıklar
2. Biçimbirimsel Çözümleyici (Morphological Analyzer)
3. Sözcük Türü Etiketleyici (POSTagger)
4. Çeviri Sözlüğü (Bilingual Dictionary Module)
5. Örüntü İşleme (Pattern Processing Module)
6. Biçimbirimsel Üretici (Morphological Generator)
7. Son İşleme (Post Generator)
8. Biçim Yapıştırıcı (formatter) : RTF ve HTML etiketlerini geri yapıştırır.

Bu modüllerden temel işlevlere sahip olan biçimbirimsel çözümleyici, çeviri sözlüğü, biçimbirimsel üretici ve son işleme modülleri sonlu durumlu makineler kullanılarak gerçeklenmiştir. Çeviri, temelde sözcük bazında yapılırken bazı durumlarda sözcük öbeklerinin çevirisi yapılmaktadır. Sözcük türü etiketleyici modülünde 2-gram ve 3-gramlardan oluşturulmuş HMM kullanılmıştır. Sözcüklerin çevrilmesi aşamasında kullanılan çift dilli aktarım sözlüğü, kaynak dildeki her bir sözcük için hedef dilde sadece bir sözcük karşılık düşürmektedir. Bunun nedeni olarak da, farklı anlamlara sahip eşadlı (homoynm) sözcüklerin her iki dilde de aynı şekilde ifade edilmesi gösterilmiştir.

Bu projenin sonuçlarında İspanyolcadan Katalancaya çeviride (üretilen metnin kabul edilebilir olması için gereken sözcük ekleme, silme ya da değiştirme adetleri bazında ölçülen) hata oranı %5 iken ters yönde (Katalanca-İspanyolca) çevirilerde daha kötü bir başarı sağlandığı belirtilmiştir.

Yakın tarihte, bu proje açık kaynak kodlu hale getirilerek Apertium ismi ile genel kullanıma açılmıştır [8]. Bu sistem ile İspanyada çok az kişinin konuştuğu bazı dillerle (Aranese Occitian gibi) İspanyolca arasında bilgisayarlı çeviri çalışmaları gerçeklenmiştir [9].

Devamlılık sağlayan ve pratik anlamda kullanılan bu iki temel çalışma dışında, benzer ya da akraba diller arasında bilgisayarlı çeviri için birkaç çalışma daha bulunmaktadır. Bunlardan bir tanesi, gene İspanyolca-Katalanca arasında gerçeklenen, istatistik tabanlı bir bilgisayarlı çeviri amacıyla karşılıklı tümcelerdeki sözcük öbeklerinin hizalanması (alignment) için dillerin benzerliğinin kullanıldığı bir

çalışmadır [10]. Benzer diller dikkate alındığında, eğitim derlemindeki karşılıklı tümcelerde, hem kaynak hem de hedef dildeki tümcelerde sözcük öbeklerinin aynı sıralarda bulunduğu ortaya konmuş ve istatistiksel çeviri modeli buna uygun olarak yeniden şekillendirilmiştir. Klasik anlamdaki bir istatistiksel çeviri modeli (IBM-2) ile %22.3 hata yapılırken bu yöntemle %12.4 hata yapıldığı sonucuna ulaşılmıştır.

Türk dilleri arasında bilgisayarlı çeviri ile ilgili bilinen ilk çalışma Azeri ile Türkçe arasında bir çeviri sisteminin gerçeklendiği çalışmadır [11]. Bu çalışma ile ilgili detaylar gerekli.

Türk dilleri arasında bilgisayarlı çeviri amaçlı bir başka çalışma ise Kırım Tatarcası ve Türkçe arasındadır [12]. Bu çalışmada 5300 adet sözcük içeren bir çeviri sözlüğü hazırlanmış ve bu sözlük kullanılarak sözcük bazında çeviri yöntemi gerçeklenmiştir. Çalışmada sadece Türkçe'den Tatarcaya çeviri yapılmış, Tatarcadan Türkçe'ye çeviri gerçeklenmemiştir. Türkçe için Oflazer'in biçimbirimsel çözümleyicisi kullanılmış [13] ve Kırım Tatarcası için biçimbirimsel çözümleyici tasarlanmıştır [14]. Kullanılan biçimbirimsel çözümleyiciler kural tabanlıdır ve sonlu durum makineleri kullanılarak tasarlanmışlardır. Çeviri sözlüğünden, kaynak dilde eklerine ayrılmış sözcük kökünün karşılığı bulunmakta ve bu karşılık ile ilgili eklerin hedef dildeki karşılıkları birleştirilerek sözcük Tatarca olarak yeniden oluşturulmaktadır.

Biçimbirimsel çözümleme sonucu ortaya çıkabilecek çözümlemeler birden fazla olabilir. Altıntaş'ın çalışmasında, üretilen birden fazla sonucun teke indirilmesi (morphological disambiguation) için herhangi bir yöntem kullanılmadığı için her sözcüğün olası her çözümlemesi için giriş tümcesi Tatarcaya çevrilmektedir. Bu da bir giriş tümcesi için birden fazla karşılığın çıkması anlamına gelmektedir. Anılan çalışmada ikinci bir olumsuz yön ise sözcük karşılığını çeviri sözlüğünde bulmakta yaşanmaktadır. Tatarca karşılığı olarak seçilen Türkçe sözcüğün anlamına göre Tatarcada farklı sözcükler olabilir ve bu sözcüklerden hangisinin seçileceğinin belirlenmesi gerekmektedir. Ancak çalışmada çalışmada bu belirsizlik de giderilmemiştir.

1.4. Tezin Bölümleri

Bu tezin bölümleri şu şekilde düzenlenmiştir: 2. Bölüm'de, doğal dil işleme alanında kullanılan ve tez çalışmasında faydanılan temel teknikler tanıtılmıştır. 3. Bölüm,

bilgisayarlı çeviri aşamalarını, otomatik çeviri sistemlerinin karşılaştıkları zorlukları ve kullanılan yaklaşımların ayrıntılarını içermektedir. 4. Bölüm'de, Türk Dil Ailesi içerisinde yer alan dillerin ortak ve farklı yönleri ile bu dillerle ilgili özet bilgiler verilmiştir. 5. Bölüm'de, Türk Dilleri arasında bilgisayarlı çeviri konusu incelenmiş ve tez çalışmasında kullanılan yöntemlerin kuramsal ayrıntıları açıklanmıştır. 6. Bölüm'de, kuramsal olarak tanıtılan yöntemin, Türkmence'den Türkçe'ye gerçeklenen bir uygulaması ve yöntem üzerinde uygulama aşamasında gerekli görülen değişiklikler anlatılmıştır. 7. Bölüm'de ise gerçeklenen uygulamanın sonuçları ve başarım değerlendirmeleri karşılaştırmalı olarak verilmiştir. 8. Bölüm, çalışma ile ilgili son değerlendirmeleri ve yorumları içermektedir.

2. DOĞAL DİL İŞLEME TEKNİKLERİ

Doğal dili işlemek için değişik bilgi düzeylerinde işlem yapan farklı biçimsel modeller ve kuramlar kullanılmaktadır. Bunlar çoğunlukla bilgisayar bilimleri, matematik ve dilbilimi alanlarında yaygın olarak kullanılan tekniklerdir. Bunlar arasında sonlu durumlu yöntemler (sonlu durumlu tanıyıcılar, sonlu durumlu dönüştürücüler, Markov Modelleri, Hidden Markov Modelleri vb.), biçimsel kural sistemleri (düzenli ifadeler, bağlamdan bağımsız gramer, vb.), arama yöntemleri (derinliğine arama, ilk en iyiyle arama, A^*) ve olasılık kuramına dayanan makine öğrenmesi yöntemleri sayılabilir. Doğal dil işlemede kullanılan tekniklerin çok geniş bir konu yelpazesine sahip olmasına karşın bu bölümde sadece yapılan çalışma ile ilintili yöntemler tanıtılacaktır anlatılacaktır.

2.1. Sonlu Durumlu Makineler

Sonlu sayıda durum, bu durumlar arası geçişler ve bu geçişler sırasında yapılan işlerle modellenen davranış şeklini gerçekleyen yapıya "sonlu durumlu makine" adı ismi verilmektedir. Sonlu durumlu makineleri tanımlamak için aşağıdaki kavramlar kullanılır kullanılmaktadır:

1. $Q : \{q_1, q_2, \ldots, q_n\}$ gibi sonlu sayıda durum içeren durumlar kümesi
2. Σ : sonlu sayıda elemandan oluşan giriş abecesi
3. q_o : başlangıç durumu
4. $\delta(q,a)$: durum geçiş fonksiyonu. Sistem $q \in Q$ durumunda iken $a \in \Sigma$ girişi gelirse, sistemin geçeceği bir sonraki $\bar{q} \in Q$ durumunu döndüren fonksiyondur. Bu yüzden $Q \times \Sigma \rightarrow Q$ üzerinde bir bağıntı tanımlar.
5. $F : \{f_1, f_2, \ldots, f_m\}$ gibi sonlu sayıda kabul durumunu içeren küme. $F \subseteq Q$

Bu kavramlar ışığında sonlu durumlu bir M makinesi aşağıdaki gibi tanımlanır:

$$M=(Q,\Sigma,q_0,\delta,F) \quad (2.1)$$

2.1.1. Düzenli Anlatımlar İfadeler ve Düzenli Diller

Düzenli anlatımlar ifadeler (regular expression) Σ abecesi üzerinde tümevarımla tanımlanır:

- Boş katar ε ve Σ abecesinin elemanları a $(\forall a \in \Sigma)$ bir düzenli anlatımdır ifadedir.
- A ve B düzenli anlatımlar ifadeler olmak koşulu ile $A \bullet B$ (bitiştirme), $A \mid B$ (veya) ve $A^* = \varepsilon \mid A \mid A^2 \mid A^3 \mid \ldots$ (Kleene yıldızı) işlemleri sonucu oluşan anlatımlar da birer düzenli anlatımdır.

Belirli bir Σ abecesindeki harflerin oluşturdukları harf dizilerini içeren kümeye **dil** (language) adı verilir. Dil, boş küme olabileceği gibi sonlu ya da sonsuz sayıda elemana da sahip olabilir.

Belirli bir Σ abecesi üzerinde tanımlı **düzenli dillerin** (regular language) özyinelemeli tanımı aşağıdaki gibidir:

- Hiçbir eleman içermeyen boş dil $\varnothing$, bir düzenli dildir.
- Boş katar $\{\varepsilon\}$ ve Σ abecesinin elemanları $\{a\}$ $(\forall a \in \Sigma)$ bir düzenli dildir.
- A ve B düzenli diller olmak koşulu ile $A \cup B$ (birleşim), $A \bullet B$ (bitiştirme) ve A^* işlemleri sonucu oluşan diller de birer düzenli dildir.
- Σ üzerinde tanımlı diğer diller içerisinde bu şekilde üretilemeyen dillerin hiçbirisi düzenli dil olamaz.

Düzenli anlatımlar ifadeler ile ona ilişkin diller arasındaki ilişki aşağıdaki gibidir:

- $L(\varepsilon) = \{\varepsilon\}; L(a) = \{a\}; \ (\forall a \in \Sigma)$
- A ve B düzenli anlatımlar ifadeler ise $L(AB) = L(A)L(B)$
- A ve B düzenli anlatımlar ifadeler ise $L(A \mid B) = L(A) \cup L(B)$
- A bir düzenli anlatım ifade ise $L(A^*) = L^*(A)$

Düzenli anlatımlar ifadeler ve onları temsil eden düzenli dil genelde karıştırılır karıştırılmaktadır. Düzenli dil, grameri düzenli olan bir dildir. Ayrıca düzenli dil, bir küme olarak tanımlanır.

Örnek olarak aşağıda çift sayıda ***a*** harfi içeren harf dizilerini gösteren düzenli anlatım ifade ve bu dilin tanımladığı düzenli dil gösterilmiştir:

```
R = [b*ab*a]*b*
L = {ε,aa,baa,baba,babab,bbaba,bbabba,babababa,babababbb,…}
```

Görüldüğü gibi basit bir düzenli anlatım ifade *R* ile sonsuz sayıda harf dizisini içeren bir dil *L* (küme) tanımlanmıştır.

2.1.2. Sonlu Durumlu Tanıyıcılar

Sonlu durumlu bir makine, kendisine giriş olarak verilen bir $w \in \Sigma^*$ harf dizisinin, Σ abecesi üzerinde tanımlanan belirli bir düzenli dilde olup olmadığına karar verebilir (tanıyabilir). Bu tür bir kullanıma sonlu durumlu makinelerin **tanıma** (recognize) amaçlı kullanımı adı verilir.

Tanıma süreci şu şekilde işler: başlangıç q_o durumundan itibaren, girişteki diziden bir harf alınır ve δ fonksiyonu uyarınca bir sonraki duruma geçilir. Giriş dizisindeki harfler bitene kadar bu işlem tekrarlanır. Son harf de tüketildikten sonra *M* makinesinin bulunduğu durum, *F* yani kabul kümesi durumlarından bir tanesi ise giriş olarak verilen harf dizisi kabul edilmiş olur.

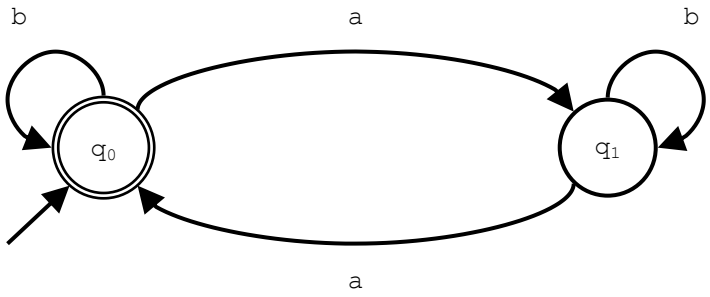

Şekil 2-1 : Örnek bir sonlu durumlu tanıyıcı

Şekil 2-1'de görülen örnek sonlu durumlu tanıyıcı aşağıdaki biçimde tanımlanmıştır:

$Q = \{q_0, q_1\}$

$\Sigma = \{a, b\}$

$F = \{q_0\}$

$\delta = \{((q_0,a),q_1), ((q_0,b),q_1), ((q_1,a),q_0), ((q_1,b),q_1)\}$

Çift daire içerisine alınan durumlar genellikle kabul durumlarını göstermektedir. Bu tanımlamalara göre bu makine *w=b, w=bbb, w=baba, w=abab* ... gibi birçok girişi kabul etmekte iken *w=a, w=ab, w=abb, w=bababa,* ... gibi girişleri tanımamaktadır.

Sezgisel olarak bu makinenin, *"içerisinde çift sayıda a geçen girişleri tanıdığını, tek sayıda a geçen girişleri ise ret ettiğini"* söyleyebiliriz.

Sonlu durumlu tanıyıcıların en önemli özelliklerinden bir tanesi sonlu sayıda eleman ile (durum, abece ve geçiş fonksiyonu) sonsuz sayıda girişin işlenebilmesidir, yani giriş dizisinin üzerinde herhangi bir sınırlama bulunmamaktadır.

Sonlu durumlu makinelerin kabul ettiği dile $L \subseteq \Sigma^*$ düzenli dil adı verilmektedir. Düzenli ifadeler ile tanımlanan düzenli diller, sonlu durumlu tanıyıcılarla tanınırlar.

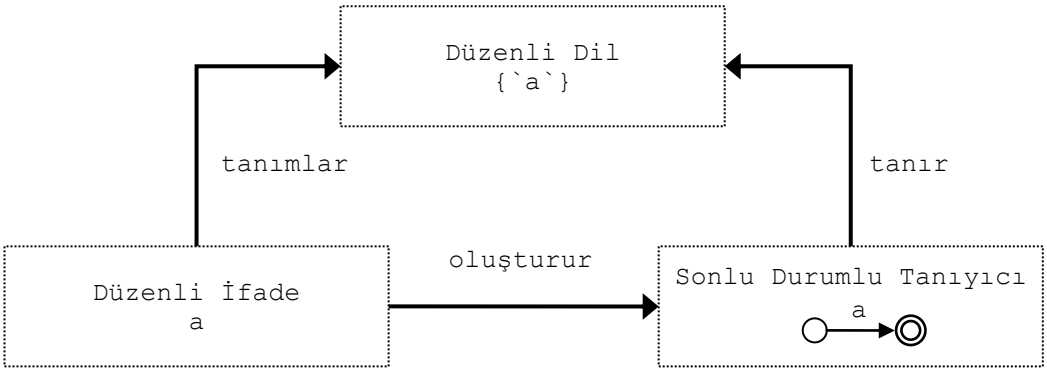

Şekil 2-2 : Düzenli ifade - düzenli dil - sonlu durumlu tanıyıcı arasındaki ilişki

2.1.3. Sonlu Durumlu Dönüştürücüler

Sonlu durumlu dönüştürücülerin (SDD) sonlu durumlu makinelerden tek farkı, girişlere göre durum geçişi yaparken çıkış üretmeleri olarak gösterilebilir. Düzenli bağıntılar, ***a:u*** sembol çiftlerinden (**a**:alt, **u**:üst) oluşan bir abece üzerinde bir düzenli anlatım ifade ile tanımlanabilir. Bu semboller boş katar olabilir. Örneğin ***a*** harfi ile başlayan sözcüklerin baş harfini büyük ***A*** yapan bir SDD aşağıda verilmiştir:

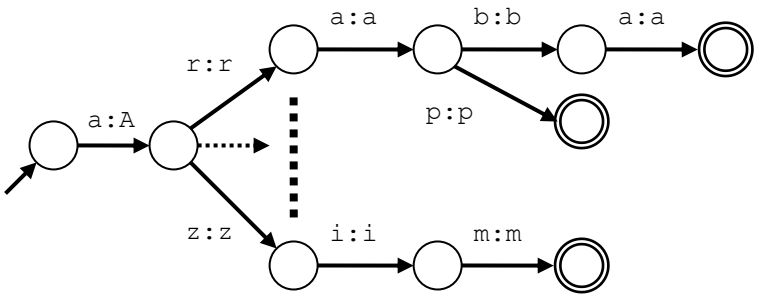

Şekil 2-3 : Sonlu durumlu dönüştürücü örneği

Sonlu durumlu dönüştürücüler, birleştirilip kullanılabilirler. Bu durumda birisinin çıkışı, diğerinin girişi olmaktadır:

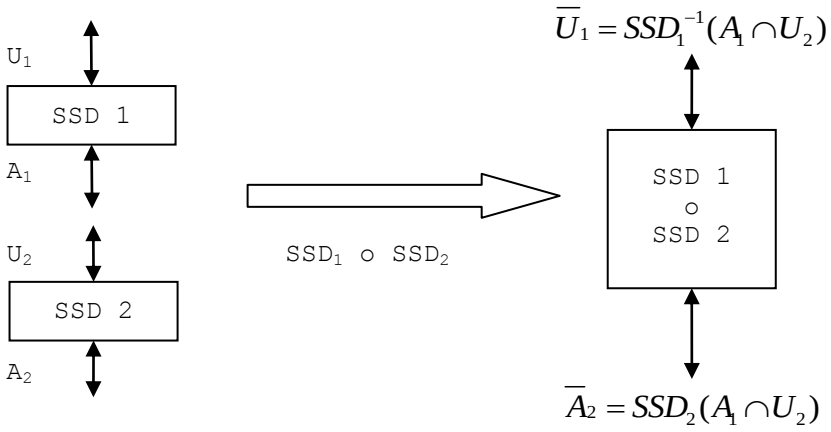

Şekil 2-4 : SSD'lerin birleştirilmesi

Şekil 2-5'te SSD'nin doğal dil işlemede örnek kullanımlarından bir tanesi verilmiştir. Şekildeki dönüştürücü aşağıdan yukarıya doğru biçimbirimsel çözümleyici, yukarıdan aşağıya doğru ise biçimbirimsel üretici olarak çalışmaktadır.

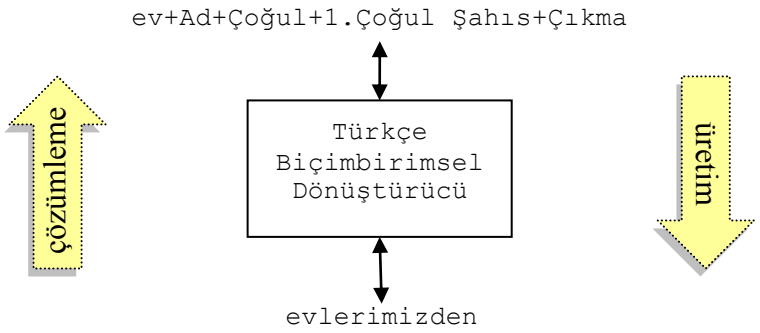

Şekil 2-5 : Türkçe biçimbirimsel dönüştürücü

2.2. Biçimbirim

Sözcükleri, sözcük türlerini, kökler ve eklerle ilgili her konuyu, yani dilin yapı özelliklerini inceleyen dilbilgisi dalına **biçimbirim** (morphology) adı verilir. Doğal dil işleme alanında her türlü işlemin ön koşulu, sözcüklerin incelenmesi ve bu sözcüklerden gerekli bilgilerin çıkartılmasıdır. Teknik anlamda biçimbirim çözümlemesi de sözcüklerin bilgi taşıyan alt yapılarına ayrılması sürecini tanımlamaktadır. Bu alt yapılara **biçem** (morpheme) adı verilir. Biçemler sözcük kökü olabileceği gibi tekillik/çokluk bilgisi, durum bilgisi ya da kip bilgisini taşıyan ekler de olabilir. Kök sözcükler gibi tek başına kullanılabilen biçemlere **serbest biçem** (free morpheme), yalnızca serbest biçemlere eklenerek kullanılabilen

biçemlere ise **ek biçemi** (bound morpheme) denir. Diller biçemlerine göre dörde ayrılır:

1. Yalıtımlı Diller (Isolated Languages)

   Sözcüklere ek biçemlerinin eklenemediği dillerdir.

   Örnekler: Mandarin Çincesi

2. Bitişken Diller (Agglutinative Languages)

   Bu tür dillerde, serbest biçemlerden sonra bir ya da birkaç ek biçemi bitiştirilerek yeni sözcükler oluşturulur.

   Örnekler: Türkçe, Macarca, Fince

3. Çekimli Diller (Inflectional Languages)

   Bir ek biçeminin birden çok bilgiyi içerdiği dillerdir.

   Örnekler: Latince ve Çekçe

4. ?? Diller (Polysynthetic Languages)

   Yalıtımlı dillerin tam tersine, bir sözcük içerisinde birden fazla sözcüğün (başka dillerde ayrı yazılan eylem, belirteç gibi birçok sözcüğün) bulunduğu dillerdir.
   Örnekler : Eskimo Dili, Sibirya'da ve Kafkasya'da konuşulan bazı diller bu sınıftandır.

Biçimbirimin sınıflandırılması ise üç türlüdür:

1. **Türetme**

Biçemlerin eklenmesi yolu ile ilk sözcükten farklı bir sözcüğün (genellikle farklı bir sözcük türünden) elde edilmesidir. Örneğin Türkçe'de "***yasak***" isim türlü sözcüğünden "***+lı***" biçemi ile "***yasaklı***" sıfatı türetilmektedir. Sözcük türünün değişmediği bir örnek olarak da "***kapı***" isminden türetilen "***kapıcı***" ve ikinci kez türetilen "***kapıcılık***" örnekleri verilebilir. Burada sözcük türü değişikliği değil sadece anlamsal bir değişiklik gözlenir.

2. **Çekim**

Sözcük türünü değiştirmeyen, sadece tekillik/çokluk, kişi, iyelik, durum, kip gibi ek bilgiler kazandıran biçemlerin eklenmesidir. Örnek olarak Türkçe'de "***adam***"

sözcüğünün çekimlenerek çoğul ve çıkma durumu belirten "***adamlarda***" sözcüğünün üretilmesi bu tür bir çekim olayıdır.

3. Birleşik Sözcükler

Özellikle serbest biçemlerin iki veya daha fazlasının birleştirilerek yeni sözcüklerin üretilmesidir. Örneğin Almanca, Hollandaca ve Danimarkaca gibi dillerde aşırı derecede birleşik sözcük kullanımı görülür. Buna örnek olarak çoğu kaynakta gösterilen "***Lebensversicherungsgesellschaftangesteller***" (sigorta şirketi çalışanı) sözcüğü gösterilebilir. Bu sözcük "***versicherung***" (sigorta), "***gesellschaft***" (şirket), "***angesteller***" (çalışan) sözcüklerinin birleştirilmesinden oluşturulmuştur.

Biçimbirimsel çözümlemenin bilgisayar yardımı ile yapılmasına ilişkin çalışmalar, Koskenniemi tarafından ortaya konulan "iki düzeyli biçimbirimsel çözümleme" isimli çalışmadan [15] sonra önemli ölçüde baş döndürücü bir şekilde hızlanmış ve bu amaçla çeşitli araçlar hazırlanmıştır.

2.2.1. İki Düzeyli Biçimbirimsel Çözümleme

İki düzeyli biçimbirim (two-level morphology) yöntemi, biçimbirimsel çözümlemede en sık kullanılan yöntemlerden bir tanesidir [15-18]. Bu yöntem ile Türkçe [13], Türkçe gibi bitişken dil olan Fince ve ayrıca çok daha farklı biçimbirimsel özelliklere sahip İngilizce, Japonca, Fransızca, Rumence gibi birçok dil için biçimbirimsel çözümleyiciler geliştirilmiştir [19-22].

Adından da anlaşılacağı gibi bu yöntem, bir sözcüğün **yüzeysel biçim** (surface representation) ve **yapısal biçim** (lexical representation) şeklinde iki türlü gösterimine dayanmaktadır. Yüzeysel biçim, sözcüğün çekim ve/veya türetme ekleri aldıktan sonra metin içerisinde gözlemlenen yazımsal biçimidir. Yapısal biçim ise, sözcüğün hangi biçimbirimsel yapılardan (sözcüğe eklenmiş çekim/yapım eklerinin özellikleri ve türleri, eklenme sıraları vb.) oluştuğunun belirtildiği biçimdir.

```
Yapısal Biçim: ev + AD + ÇOĞUL + 1.TEKİL ŞAHIS İYELİK + BULUNMA HALİ
Yüzeysel Biçim: evlerimde
```

Yapısal gösterimde belirtilen bu biçimbirimsel özelliklerin ekleri, çeşitli ses ve harf değişikliklerine uğrayarak sözcüğe eklenmekte ve sonuçta sözcüğün yazımda kullanılan *yüzeysel biçimi* ortaya çıkmaktadır.

İki düzeyli biçimbirim yöntemi, iki bileşenden oluşur:

1. **Yazım Kuralları**

   Bu bileşen ile yapısal biçimden yüzeysel biçime geçerken, yani sözcüğün yazıdaki hali oluşurken meydana gelen harf değişiklikleri ve ses olayları modellenir.

2. **Bitiştirme Kuralları**

   Sözlükte yer alan sözcük köklerine hangi eklerin gelebileceği ve geçerli bir sözcüğün oluşması için bu eklerin geliş sıraları bu bileşen yardımı ile modellenir.

Yapısal biçim ile yüzeysel biçim arasında dönüşümler, sonlu durumlu dönüştürücülerle SDD gerçeklenmektedir.

2.2.1.1. Yazım Kuralları

Yapısal biçimden yüzeysel biçime geçerken yazım kuralları (ortographic rules) uyarınca harflerde değişmeler olur. Bu kuralların modellenmesini sağlayan bileşendir. Örneğin Türkçe'deki "***karın***" sözcüğünün sesli ile başlayan bir ek alması durumunda, "***ı"*** harfinin düşerek "***karnı***" şeklinde yazılması bu tür bir değişikliktir. Benzer şekilde sesli uyumlarına göre eklerin sesli harflerinin değişmesi (ör. ***+l<u>e</u>r/+l<u>a</u>r***), sessiz benzeşmesi (***yaz+<u>d</u>ım/aç+<u>t</u>ım***), kaynaştırma harflerinin oluşması (***iste+<u>y</u>+ecek / döv+ecek***) gibi bir çok ses olayı da bu değişimlere örnek olarak sayılabilir.

Bu ses değişiklikleri, Tablo 2-1'deki 4 temel kural türü ile ifade edilebilmektedir [18].

Bu kurallar kullanılarak, dildeki ses olaylarını modelleyen SDD gerçeklenir. Daha sonra bu dönüştürücüler, bitiştirme kuralarını modelleyen SDD ile birleştirilerek kullanılır.

Tablo 2-1 : İki düzeyli biçimbirimde kural türleri

a:b => LC _ RC	Yapısal gösterimdeki bir 'a' sesi, kendinden önce ve sonra belirtilen bağlamlar varsa (LC - left context ve RC – right context) yüzeysel biçimde 'b' sesine **dönüşebilir**, (ancak bu dönüşüm zorunlu değildir).
a:b <= LC _ RC	Yapısal gösterimdeki bir 'a' sesi, kendinden önce ve sonra belirtilen bağlamlar varsa (LC - left context ve RC – right context) yüzeysel biçimde 'b' sesine **mutlaka dönüşür** (bu dönüşüm zorunludur, koşullar sağlandığında gerçeklenmelidir).
a:b <=> LC _ RC	Yapısal gösterimdeki bir 'a' sesi, kendinden önce ve sonra belirtilen bağlamlar varsa (LC - left context ve RC – right context) yüzeysel biçimde 'b' sesine **mutlaka dönüşür**, (bu dönüşüm zorunludur) ve **başka hiçbir bağlamda bu dönüşüm olmaz**.
a:b /<= LC _ RC	Yapısal gösterimdeki bir 'a' sesi, kendinden önce ve sonra belirtilen bağlamlar varsa (LC - left context ve RC – right context) yüzeysel biçimde 'b' sesine **kesinlikle dönüşemez**.

2.2.1.2. Bitiştirme Kuralları

Bu bileşen kapsamında köklerden oluşan bir sözcük listesi ve bu sözcüklerin türleri bulunur. Bileşen ayrıca hangi eklerin, hangi sözcüklerden sonra hangi sıralarla gelebileceği bilgilerini de içermektedir. Bu bileşen kök sözcükler, sözcük türleri ve ekleri içeren bir SDD ile gerçeklenebilir. Bu SDD, eklerin köklere bitiştirildiği varsayımı ile çalışmaktadır. İki düzeyli biçimbirimsel araçların çoğunda, eklerin bitiştirme modeli, sözlüğün alt parçaları arasında geçiş yapma ilkesine dayanır [21, 23]. Örneğin kök sözcüğe bir ek geldiğinde hangi **alt sözlükten** (lexicon) devam edileceği belirtilir. XEROX araçları için örnek bir sözlük düzeni şekil gösterilmiştir. Ref vermek gerekmez mi?

Bu sözlük girdilerinin her bir satırı sırasıyla üst simge, alt simge ve bir sonraki adımda geçilecek alt sözlüğün isminden oluşur. Örneğin işaretli girdi ile, alt simge olarak ***+lAr*** eki görüldüğü zaman üst simge olarak ***+COK*** etiketinin oluşturulması ve bir sonraki adımda ***IYELIK_ETIKETI*** isimli alt sözlükten devam edilmesi gerektiği belirtilir [23].

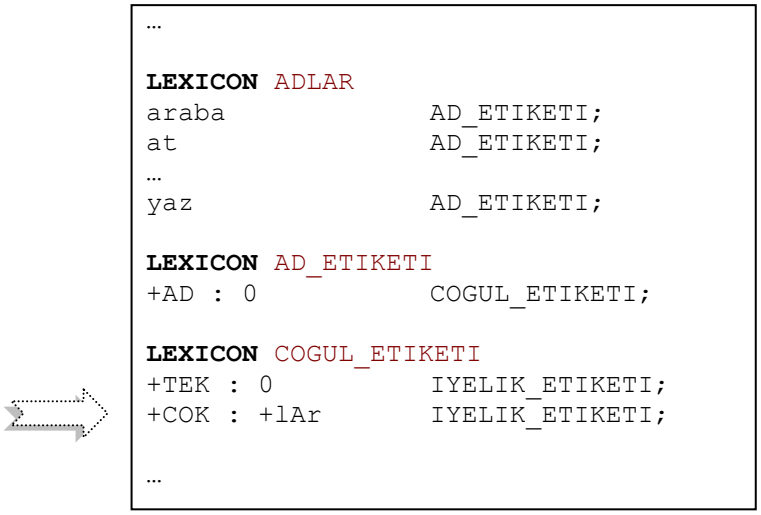

Şekil 2-6 : "Xerox Lexc" için sözlük yapısı

2.2.1.3. Sonlu Durum Dönüştürücülerinin Birleştirilmesi

Yazım kurallarını modelleyen SDD ile bitiştirme kurallarını modelleyen SDD birleştirilerek tek bir SDD haline getirilir ve iki-düzeyli biçimbirimsel çözümleyici elde edilir. Oluşan SDD, her iki yönde, çözümleme ve üretim amaçlı çalıştırılabilir.

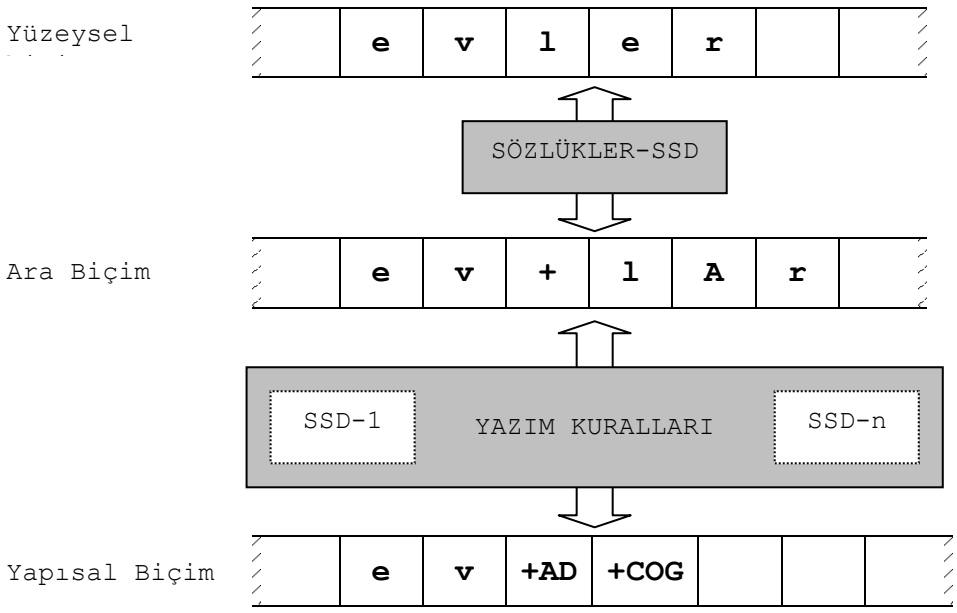

Şekil 2-7 : İki düzeyli biçimbirimsel çözümleyici/üretici

2.3. İstatistiksel Dil Modelleri

Doğal dil işlemenin konuşma tanıma, el yazısı tanıma, istatistiksel bilgisayarlı çeviri gibi birçok alt kolunda sıklıkla istatistiksel dil modelleri (statistical language model) kullanılmaktadır [24].

İstatistiksel dil modellerinin (İDM ya da DM) temel ilkesi, herhangi bir tümce içerisindeki bir sözcüğün, bu sözcükten önceki sözcüklere bakılarak öngörülmesidir kestirilmesidir (söylemek istediğin, önceki sözcüğe bakarak tahmin etmek diye düşündüm, "Estimate" karşılığı olarak kestirimi kullanılır). Tanım olarak istatistiksel dil modelleri, tümceleri oluşturan sözcük dizilerinin olasılık dağılımlarını ifade etmektedir.

s_1 s_2 s_3 ... s_K sözcük dizisinden oluşan bir C tümcesinin olasılığı, zincir kuralına (chain rule) uygun olarak açılarak aşağıdaki şekilde hesaplanabilir:

$$P(C)=P(s_1)P(s_2|s_1)P(s_3|s_1s_2)...P(s_K|s_1...s_{K-1}) \quad (2.2)$$

Denklem (2.2)'de yer alan olasılıklar, bir eğitim derlemindeki (corpus) sözcük dizilerinin sayılması ile hesaplanmaktadır. Ancak uygulamada, C tümcesinde yer alan tüm sözcüklerin, birebir aynı sırada eğitim derleminde de geçmesi olası değildir. Örneğin tümcenin son sözcüğü s_K'ya ait $P(s_K|s_1...s_{K-1})$ olasılığının hesaplanması için eğitim derleminde s_K'nın tüm geçmişinin (history) yani $s_1...s_{K-1}$ bulunması zorunludur. Olasılıkların bu şekilde hesaplanması durumunda çoğu olasılık çarpanı, seyrek veri sorunundan dolayı sıfır olacaktır. Bunu engellemek için, bir tümcenin olasılığı belirlenirken sözcüklerin belirli sayıda geçmişi kullanılarak yaklaşık bir olasılık hesaplanır. Bu bağlamda bir tümcenin olasılığı aşağıdaki şekilde hesaplanır:

$$P(C) \approx P(s_1)P(s_2|s_1)P(s_3|s_1s_2)...P(s_K|s_{K-n+1}...s_{K-1}) \quad (2.3)$$

Örneğin, her sözcüğün kendisinden önceki sadece bir sözcüğe bağlı olduğu bir modelde (1. dereceden İDM) olasılık denklemi şu şekilde ifade edilir:

$$P(C)=P(s_1)P(s_2|s_1)P(s_3|s_2)...P(s_K|s_{K-1}) \quad (2.4)$$

N-gram yapıları da İDM ile aynı olasılık dağılımını ifade etmektedir. N-gram modellerinde olasılıklar, sözcüklerin N-1 adet geçmişi kullanılarak hesaplanır.

Örneğin 3-gram modelinde bir sözcüğün olasılığı, kendisinden önceki 2 sözcük tarafından belirlenir.

İDM ile N-gram arasındaki tek fark, seçilen geçmiş sözcük sayısının belirtilmesindedir. Örneğin 3. dereceden (3rd order) bir DM, geçmiş olarak 3 sözcük kullandığı için 4-gram modeli ile aynıdır.

DM'deki olasılıkların çıkarılması ise **En Büyük Olabilirlik Kestirimi** (Maximum Likelihood Estimation) yöntemine göre eğitim derlemindeki sözcüklerin sayılması esasına dayanmaktadır [25] :

$$P(s_i \mid s_{i-n+1},...,s_{i-1}) \approx \frac{C(s_{i-n+1},...,s_i)}{C(s_{i-n+1},...,s_{i-1})} \tag{2.5}$$

Bu denklemde $C(s_i,...,s_j)$ ifadesi, derlemde $s_i,...,s_j$ sözcük dizisinin kaç defa geçtiğini göstermektedir.

2.3.1. Yumuşatma (Smoothing)

İDM'lerin uygulamasındaki sorunlardan en önemlisi, olasılıkların hesaplandığı eğitim derleminin sınırlı olmasından kaynaklanmaktadır. Olabilecek her türlü sözcük sıralaması, bu derlem içerisinde olmayabilir. Bu durumda bazı olasılıklar sıfır olarak hesaplanacaktır. Aslında genellikle, olasılığı sıfır olan n-gramların sayısının diğerlerinden çok daha fazla olduğu görülmüştür. Bunu engellemek ve eğitim derleminin sınırlı olmasından dolayı olasılığı sıfır olarak hesaplanan ancak gerçekte sıfır olmayan sözcük sıralamaları için bir iyileştirme yapılmalıdır. Bu iyileştirme ise, olasılığı sıfırdan farklı sözcük sıralamalarından bir miktar olasılık dağılımını "çalarak", olasılığı sıfır olanlara "dağıtmak" şeklinde gerçeklenebilir. Bu tür yöntemler, olasılığı sıfırdan farklı olan sözcük sıralamalarında yapılan azaltmaya, indirmeye atfen "indirim" (discounting) olarak adlandırılmaktadır.

Anılan iyileştirme yöntemleri arasında birkaç yöntem bulunur:

- Bir Fazla Sayma Yöntemi [26]
- Witten-Bell İyileştirme Yöntemi [27]
- Good-Turing İyileştirme Yöntemi [28]

Bir başka iyileştirme yöntemi de derece düşürme (back-off) yöntemidir [29]. Bu yöntemde, eğer derlemde bir sözcük sıralamasına hiç rastlanmamışsa, bu sözcük sıralamasının olasılığı hesaplanırken bir mertebe daha düşük dil modeline geçilir. Örneğin aranılan 3-gram'a, $P(w_3|w_1w_2)$, ilişkin bir örnek derlemde yoksa, bir derece daha düşük olan 2-gram modeline geçilir ve burada $P(w_2|w_1)$ olasılığı hesaplanır. Sonuçta aşağıdaki n. dereceden bir sözcük sıralamasının olasılığı, aşağıdaki formül ile hesaplanabilir:

$$P(w_i \mid w_{i-2}w_{i-1}) = \begin{cases} P(w_i \mid w_{i-2}w_{i-1}) & ,eğer\ C(w_{i-2}w_{i-1}w_i) > 0 \\ \alpha(w_{n-2}^{n-1})P(w_i \mid w_{i-1}) & ,eğer\ C(w_{i-2}w_{i-1}w_i) = 0\ ve \\ & \quad C(w_{i-1}w_i) > 0 \\ \alpha(w_{n-1})P(w_i) & ,\ diğer\ durumlarda \end{cases} \tag{2.6}$$

Bu denklemdeki α katsayısı ve düzeltilmiş olasılıklar P, olasılık dağılımı toplamının 1 olması için yeniden hesaplanmış olasılıkları göstermektedir.

Anılan iyileştirme yöntemlerinin ayrıntıları burada ele alınmayacaktır; ancak bu konularda ayrıntılı bilgi için [25, 30] kaynakları incelenebilir. Ek olarak, farklı türdeki iyileştirme yöntemlerinin karşılaştırmalarının ve başarımlarının performanslarının ayrıntılı detaylı biçimde incelenmesi için [31] kaynağına başvurulabilir.

2.3.2. İDM Değerlendirmesi

İDM'lerin değerlendirilmesinde en sık kullanılan ölçütler, **entropi** ve **preplexity** (bu ikisine birer Türkçe karşılık bulalım) ölçütleridir. Bu iki ölçütün tanımlaması bilişim kuramı (information theory) çerçevesinde yapımaktadır.

Bilginin bir ölçüsü olan entropi, öngörü yapılacak veri kümesi V üzerinde değer alan bir X serbest olasılık değişkeni ve buna ait $p(x)$ fonksiyonu ile hesaplanır:

$$H(X) = -\sum_{x \in V} p(x) \log_2 p(x) \tag{2.7}$$

Hesaplanan entropi değerinin biriminin ikili değer (bit) olması için logaritma tabanı olarak genellikle 2 kullanılır. Entropinin sezgisel tanımı, bir bilginin alıcı tarafa en uygun kodlama yöntemi ile kodlanarak aktarılması için gereken en düşük bit sayısıdır.

s_1, s_2, …, s_n gibi bir sözcük dizisi üzerinde tanımlanan **entropi oranı**, bir anlamda sözcük başına düşen ortalama entropi değerini belirtir. Bu değeri hesaplamak için sözcük dizileri üzerine tanımlanmış bir serbest değişken tanımlanabilir. Bu sayede belirli bir *D* dilinde tanımlı bütün *n* uzunluklu sözcük dizileri üzerinde aşağıdaki entropi hesabı yapılabilir:

$$\begin{aligned} H(D) &= -\lim_{n\to\infty}\frac{1}{n}H(s_1 s_2 ... s_n) \\ &= -\lim_{n\to\infty}\frac{1}{n}\sum_{S\in D} p(s_1 s_2 ... s_n)\log_2(s_1 s_2 ... s_n) \end{aligned} \tag{2.8}$$

Ancak bir dile ait gerçek entropi değerinin hesaplanması için, bu sözcük dizisi uzunluğunun sınırsız olması gerekir. Eğer *D* dili, belirli koşulları sağlarsa (stationary ergodic), *D* dilinin entropi değeri aşağıdaki gibi hesaplanabilir:

$$H(D) = \lim_{n\to\infty} -\frac{1}{n}\log_2 p(s_1 ... s_n) \tag{2.9}$$

Fakat doğal dil söz konusu olduğunda, sözcük sıralarını üreten gerçek *p* olasılık dağılımının belirlenmesi mümkün değildir. Bu durumda İDM'leri değerlendirmek için **çapraz entropi** (cross entropi) kullanılır.

Bilinmeyen bir *p* olasılık dağılımı üzerine tanımlanan *m* modeline (*p* olasılığına yaklaşıklık sağlayan bir model) çapraz entropi değeri şu şekilde hesaplanır:

$$H(p,m) = \lim_{n\to\infty} -\frac{1}{n}\sum_{S\in D} p(s_1 ... s_n)\log_2 m(s_1 ... s_n) \tag{2.10}$$

D dili, gene belirli koşulları sağlarsa (stationary ergodic), denklem (2.10) aşağıdaki biçime dönüşür:

$$H(p,m) = \lim_{n\to\infty} -\frac{1}{n}\log_2 m(s_1 ... s_n) \tag{2.11}$$

Çapraz entropinin kullanışlı olan özelliği ise *H(p,m)* değerinin *H(p)* değeri ile alttan sınırlı olmasıdır:

$$H(p) \leq H(p,m) \tag{2.12}$$

Bu özellik, *p* olasılık dağılımını modelleyen iki ayrı m_1 ve m_2 modeli arasında karşılaştırma yapılmasını sağlamaktadır. Hangi modelin çapraz entropi değeri daha küçükse, bu model gerçek *p* dağılımına en yakın modeldir ve daha doğrudur. *H(p)=H(p,m)* değeri sağlandığında, *p* dağılımı tam olarak modellenmiş olur. Son olarak çapraz entropi değerinin hiçbir zaman gerçek dağılımın entropisinin altına düşemeyeceğini de belirtmekte yarar vardır.

Preplexity değeri ise $2^{H(p)}$ [24, 32] biçiminde tanımlanır. *S* sözcük dizisi üzerinde tanımlanmış *P* modelinin perplexity değeri ise aşağıdaki gibi hesaplanır:

$$Perplexity(S) = 2^{H(S)} = \sqrt[n]{\prod_{i=1}^{n} \frac{1}{P(s_i \mid s_1 \ldots s_{i-1})}} \tag{2.13}$$

3. BİLGİSAYARLI METİN ÇEVİRİSİ

İnsanlar arasındaki iletişimi kolaylaştırmak adına, bilgisayarları kullanarak diller arası çevirilerin yapılması fikri, bilgisayarın kullanılmaya başlandığı ilk yıllardan bu yana birçok araştırmacının ilgisini çekmiştir. Ancak ne yazıktır ki günümüz teknolojisi ve teknikleri ile bile yetkin ideal bir çeviri sisteminin gerçeklenmesi çok zordur uzaktır. [25]. Yetkin İdeal bir bilgisayarlı çeviri sisteminin temelde şu üç özelliği barındırması beklenir:

1. **Otomatiklik** : İnsan müdahalesine gerek kalmadan sonuç üretebilmeli
2. **Kaliteli Çeviri Yapabilme** : Sistemin ürettiği çıktılar anlaşılabilir ve asıllarına uygun olmalı
3. **Geniş Kapsamlılık** : Çeviri sistemi her türlü konuyu içeren genel metinler (makale, haber, hikaye, mektup vs.) üzerinde işlem görebilmeli

Bu üç özellik İngilizcede FAHQT (**F**ully **A**utomatic - **H**igh **Q**uality output - unrestricted **T**ext) olarak geçmektedir.

Diller arasında yetkin bilgisayarlı çeviri (BÇ) gerçeklemenin başlıca zorluğu, toplumlar arası kültür ve yaşayış farklılıklarının dillerine yansımış olmasıdır. Dili, bir anlaşma aracı olarak kullanan insanların hayat görüşleri, toplumsal yargıları, kültürleri, yaşayış şekilleri, yaşadıkları ortamların doğa koşulları gibi birçok farklı etken dillerini etkilemiştir. Bu etkiler nesnelere, kavramlara, eylemlere verilen isimlerin farklılaşmasına yol açtığı gibi tümce kuruluşlarını, vurguları ve anlatım biçimlerini de değiştirmiştir.

Bilgisayarlı çeviri her ne kadar tam anlamıyla başarılmış değilse de bu konuda sayısız çalışma bulunmaktadır. Kuşkusuz böyle bir konunun sahip olduğu ticari potansiyel, üniversite çevrelerinin dışında da bu konuyla ilgilenenlerin sayısını arttırmıştır.

Şimdiye dek yapılan çalışmalar sonucunda, eksik ve hatalı da olsa çeviri yapan uygulamalar gerçeklenmiş ve bu tür uygulamaların çeşitli alanlarda işe yaradığı görülmüştür. Gerçeklenen sistemlerin özellikleri incelendiğinde, yetkin çeviri

sisteminin temel özelliklerinden bazılarından vazgeçilmesi yoluyla ancak gerçeklenebilir sistemler üretildiği görülmektedir. Üretilen sistemler genel olarak üç ana amaçla kullanılmaktadır:

1. **Yüzeysel Çeviri**

   Bazı uygulamalarda, bir metnin yüzeysel bir çevirisi dahi iş görmektedir. Özellikle internet ortamından bilgi toplama (information acquisition) sistemleri, kötü de olsa çeviri sonuçlarını kullanarak farklı dillerde içeriklere erişebilmeyi sağlamaktadır. Bu uygulama türlerinde yetkin sistemin "yüksek kaliteli çıktılar" üretebilme özelliği göz ardı edilmiştir.

2. **Bilgisayar Destekli Çeviri (BDÇ)**

   Bilgisayarlı çeviri sistemlerinin bir diğer kullanım alanı ise insan emeği ile yapılan klasik anlamdaki çeviri işlemlerini kolaylaştıran bir araç olarak kullanılmasıdır. Bu tür uygulamalarda bilgisayarlı çeviri sisteminin ürettiği sonuçlar, doğrudan kullanılmak yerine çevirmenler tarafından düzeltilerek kullanılır. Çevirmenlerin yapacakları bu değişiklikler, çoğu kez sıfırdan çeviri yapmaktan çok daha kolay olmaktadır. Yetkin çeviri sisteminin "otomatiklik" özelliğinden vazgeçilerek gerçeklenmiş bu sistemler özellikle yüksek hacimli ve hızlı yapılması gereken çeviri işlerinde tercih edilir.

3. **Sadece Belirli Konuları İçeren Metinlerde**

   Çevrilecek metin türleri ve konuları kısıtlanarak gerçeklenen sistemlerde ise yetkin sistemin "geniş kapsamlılık" özelliği kullanılmamış olur. Bu tür sistemlerde konular ve hatta çevrilecek metinlerin dilbilgisi yapılarında bile bazı kısıtlamalara gidilir. Böyle bir sistemin en eski örneği olarak İngilizce-Fransızca arasında hava tahminlerini çeviren Météo sistemi gösterilir [33]. Hava tahmin raporları, kullanılan dil itibarı ile sabit kalıplardan ve hatta sabit sözcüklerden oluşmaktadır. Bu tür bir dil kullanımına **alt dil** (sublanguage) adı verilmektedir.

3.1. Bilgi Tabanlı Çeviri Yöntemleri

Bilgi tabanlı çeviri yöntemleri, çeviri yapmak için giriş tümcesinin çeşitli bilgi seviyelerinde gösterimlerini oluşturduktan sonra bu bilgi seviyesinde aktarım

yapılmasını öngören bir dizi yöntem kullanır. Bu yöntemleri görselleştirmek için Vauquois Üçgeni yaygın olarak kullanılır.

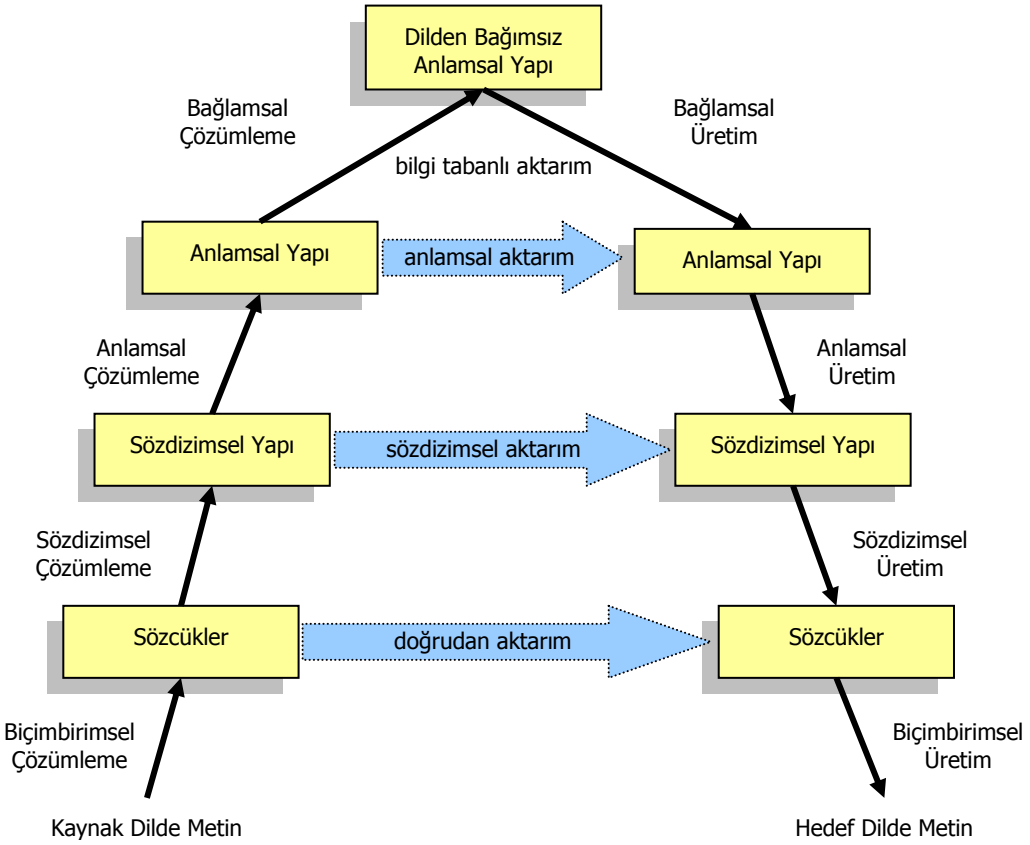

Şekil 3-1 : Bilgi tabanlı yöntemlerin sınıflandırılması-Vauqouis Üçgeni

3.1.1. Doğrudan Aktarım

En temel çeviri türü, kaynak dildeki sözcüklerinin karşılıklarının bulunarak hedef dile çevrilmesidir. Ancak bu basit yöntemde dahi birçok sorunla karşılaşılmaktadır. Bunların en önemlisi çevrilecek sözcüğün birebir karşılığının bulunmadığı durumlardır. Bu sorunlara **sözlüksel belirsizlik** (lexical ambiguity) denilmektedir. Örneğin aşağıda İngilizce "***leg***" sözcüğünün Fransızca karşılıklarının verildiği bir örnek bulunmaktadır:

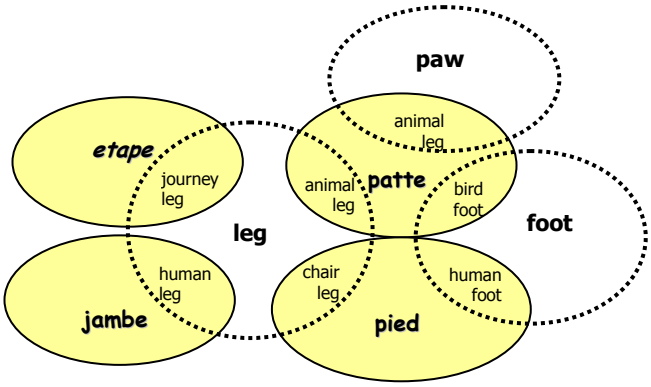

Şekil 3-2 : İngilizce-Fransızca arası sözcüksel belirsizlik örneği

Şekil 3-2'de görüldüğü gibi İngilizcede "***leg***" sözcüğü dört farklı anlamda kullanılabilmektedir; (1) bir yarışmanın, yolculuğun vb.nin ayağı, etap, (2) insan bacağı, (3) hayvan bacağı, (4) sandalye, masa bacağı. Ancak bu 4 farklı anlam için Fransızcada 4 farklı sözcük "***etape***", "***jambe***", "***patte***" ve "***pied***" bulunmaktadır. Sözcük bazında çeviri yapan sistemlerin üstesinden gelmesi gereken en büyük zorluk bu sözcüksel belirsizliğin giderilerek doğru karşılığın seçilmesidir.

Sözcük bazında çeviri yapan doğrudan aktarım yönteminin en önemli bileşeni kullanılan gelişmiş aktarım sözlüğüdür. Aslında bu sözlüğün her girdisi, belirli bir sözcüğü aktarmak için çalışan küçük bir program olarak düşünülebilir. Şekil 3-3'te İngilizce-Rusça arasında doğrudan aktarım ilkesine göre çeviri yapan bir sistemden alınan örnek bir süreç gösterilmiştir. Bu süreç ile İngilizcedeki ***much*** ve ***many*** sözcükleri Rusçaya aktarılmaktadır.

```
function Direct_Translate_Much/Many(word) returns RussianTranslation

if preceding word is "how" return "skol'ko"
else if preceding word is "as" return "skol'ko zhe"
else if word = "much"
  if preceding word is = "very" return nil
  else if following word is a noun return "mnogo"
else /* word = many */
  if preceding word is a preposition and
     following word is a noun return mnogii
  else return mnogo
```

Şekil 3-3 : Doğrudan aktarım yöntemleri için örnek aktarım süreci

Her ne kadar doğrudan aktarım yönteminde tümce üzerinde çözümleme yapılması gerekmese de birçok uygulamada biçimbirimsel çözümleme yapılır.

3.1.2. Sözdizimsel Gösterimin Aktarımı

Bilgisayarlı çeviri yöntemleri arasında diğer bir yöntem de sözdizimsel temelde çeviri yapmaktır. Buna göre kaynak dildeki sözcük öncelikle sözdizimsel olarak ayrıştırılır ve elde edilen ağaç yapısı, hedef dilde aynı anlamı taşıyan ağaç yapısına çevrilmeye çalışılır.

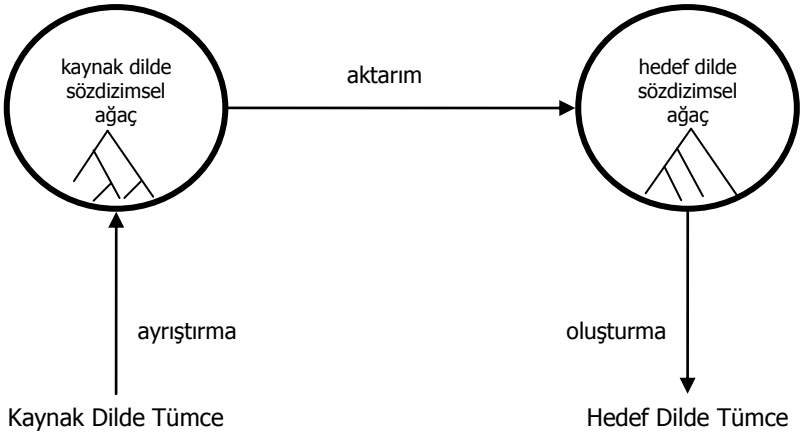

Şekil 3-4 : Sözdizimsel gösterimin aktarımı

Sözdizimsel yapının aktarılmasından sonraki süreç ise sözcüklerin aktarılmasıdır. Tıpkı doğrudan aktarım yönteminde olduğu gibi bu aşamada da her iki dilde sözcükleri içeren bir aktarım sözlüğü kullanılır. Bazı sistemlerde, bu aşamada ortaya çıkan sözcüksel belirsizliklerin giderilmesi için kaynak tümce çözümlemeleri sırasında anlamsal belirsizlik giderici yöntemler uygulanmaktadır.

3.1.3. Anlamsal Gösterimin Aktarımı

Anlamsal çeviri (semantic transfer), önce kaynak dildeki tümcenin sözdizimsel ayrıştırması yapıldıktan sonra ayrıştırılan yapılara anlamsal görevlerin rollerin (semantic role) yüklenmesi ve aktarımın bu görevlere rollere göre yapılması temeline dayanmaktadır. Yöntem, sözdizimsel çeviride karşılaşılan yapı uyuşmazlıklarının bazıları çözebilmektedir.

3.1.4. Dilden Bağımsız Anlamsal Gösterimin Aktarımı

Bilgisayarlı dil çevirisi yöntemlerinin sonuncusu ise "interlingua" adı verilen ve tümcenin taşıdığı anlamı, dilden bağımsız bir yapıda ifade eden yapıları kullanılmasıdır. Bu yöntemin temel dayanak noktası, farklı dillerde, anlamların ifade edilme biçimlerinden bağımsız bir anlam temsilidir.

Örnek olarak aşağıdaki tümcenin gösterimi Şekil 3-5'de verilmiştir:

```
Mehmet, bu güzel çöreği yemedi.
```

$$\begin{bmatrix} Olay & yemek \\ Etmen & Mehmet \\ Kip & geçmiş \\ Olumluluk & olumsuz \\ Tema & \begin{bmatrix} çörek & \\ İşaret & bu \\ Özellikler & tatlı \end{bmatrix} \end{bmatrix}$$

Şekil 3-5 : Dilden bağımsız anlamsal gösterim örneği

Bu yöntemin en yararlı yönü, ikiden fazla dil arasında çeviri yapılacağı zaman ($1 \rightarrow N$) ortaya çıkmaktadır. Diğer yöntemlerde bu tür bir işlem, toplam N^2 çeviri yapılması anlamına gelir. Halbuki kaynak tümcenin dilden bağımsız anlamsal gösterimi elde edildikten sonra, bu gösterime ilişkin tümcenin N adet dil için üretilmesi yeterlidir. Bu tür çeviri yöntemi, Avrupa Birliği gibi birçok dilin kullanıldığı ortamlar için kullanışlı olmaktadır.

Ancak "interlingua" adı verilen bu yapının kullanılmasında çok büyük bir sorun bulunmaktadır: doğal dil ile ifade edilen anlamı, başka bir biçimde sunacak olan "bilgi temsil diline" çevirmedeki güçlük. Her dilin, belirttiği özellikler farklılık göstermektedir. Örneğin Türkçe'de 3. tekil şahıslar için cinsiyet bilgisi yokken İngilizcede bulunur. Benzer şekilde Türkçe'de ***amca*** ve ***dayı*** ayrı sözcüklerle ifade edilirken İngilizcede her ikisi de ***uncle*** sözcüğü ile belirtilir. Anlamsal gösterimin dilden bağımsız olabilmesi için her dilde farklı ifade edilen kavramları içermek için de bir yol bulunması gerekmektedir. Bu farklılıklardan dolayı dilden bağımsız bir gösterimin tam olarak nasıl sağlanabileceği konusunda halen büyük boşluklar bulunmaktadır.

3.2. İstatistiksel Yöntemler

Bilgi tabanlı bilgisayarlı çeviri yöntemlerinin ana teması, kaynak dildeki tümcelerin hangi bilgi seviyesinde (sözcük, sözdizimsel yapı, anlamsal yapı gibi) işlem göreceğini belirlemek ve seçilen gösterimin hedef dile nasıl aktarılacağının yollarını araştırmak üzerine yoğunlaşır. İstatistik tabanlı yöntemler ise tamamen sonuç odaklı

çalışır ve aktarma işleminin nasıl yapılması gerektiğinden çok nasıl sonuçlanması gerektiği üzerinde durur.

İstatistiksel çeviri yöntemlerinin fikirleri 1950'li yıllarda ortaya atılmış olsa da gerçek anlamdaki çalışmalar 1990'lı yıllarda başlamıştır [34, 35]. Elektronik ortama aktarılmış, karşılıklı çevirilerden oluşan metinlerin sayısının giderek artması ve bilgisayarların yeteneklerinin hızla artması, bilgi tabanlı aktarım için kural karmaşasında boğulmakta olan çevrelerin, istatistiksel çeviri yöntemlerine doğru hızlı bir kayma yaşamasına neden olmuştur.

İstatistiksel yöntemlerin çalışma mantığı, çeviri işlemini, Shannon'un Gürültü Kanal Modeli (Noisy Channel Model) uyarınca bozulmuş bir işareti düzeltme olarak değerlendirir:

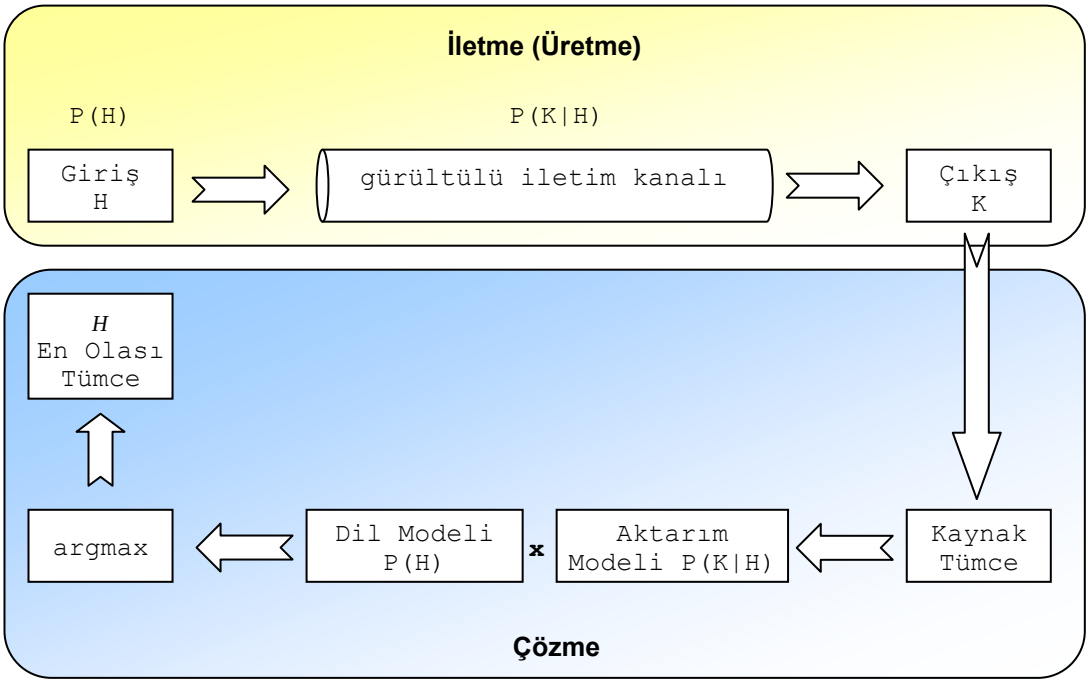

Şekil 3-6 : Gürültü Kanal Modeli uyarınca çeviri işlemi

Bu yaklaşıma göre hedef dildeki tümce *H,* iletim kanalından geçerken kanaldaki gürültü nedeniyle değişmiş ve çıkışta kaynak dildeki tümce *K* oluşmuştur. Yöntemin ilkesi, iletim kanalının çıkış ucunda gözlenen kaynak dildeki tümce *K*'dan yola çıkarak, gönderilen asıl metine yani "hedef dildeki" tümceye ulaşmaktır. Bunu sağlamak üzere aşağıdaki denklemin çözümünün bulunması yeterli olacaktır:

$$H = \underset{H \in \text{Hedef Dil}}{\arg\max}\, P(H \mid K) \tag{3.1}$$

Denklem (3.1)'deki olasılık değerini Bayes kuralına göre tekrar yazarsak:

$$H = \underset{H \in \text{Hedef Dil}}{\arg\max} \frac{P(K \mid H)P(H)}{P(K)} \tag{3.2}$$

Bu denklemde *P(K)* olasılığı bütün *H* tümceleri için sabit olduğundan *argmax* işleci için sonucu değiştirmez. Bu durumda denklem (3.2)'yi aşağıdaki gibi yazabiliriz:

$$H = \underset{H \in \text{Hedef Dil}}{\arg\max} \underbrace{P(K \mid H)}_{\text{çeviri modeli}} \underbrace{P(H)}_{\text{dil modeli}} \tag{3.3}$$

Bu denklemde iki bileşen göze çarpmaktadır. Bunlardan *P(K|H)*, **çeviri modeli** olarak adlandırılır ve hedef dildeki *H* tümcesinin, kaynak dildeki *K* tümcesinin çevirisi olma olasılığını belirtir. İkinci bileşen ise *H* tümcesinin, hedef dildeki olasılığını belirtir. Bu iki olasılık değerinin çarpımını en çoklayan *H* tümcesi sonuç olarak üretilir.

Denklem (3.3)'in sezgisel açıdan yorumu ise, kaynak dildeki *K* tümcesinin en yakın çevirisi olma (çeviri modeli bileşeni) ve aynı zamanda da hedef dil için akıcı ve geçerli bir tümce olma (dil modeli bileşeni) koşullarını birlikte sağlayan en olası *H* tümcesinin bulunmasıdır.

Sonuç olarak istatistiksel yöntemlerle bilgisayarlı çeviri yapabilmek için aşağıdaki üç bileşenin elde edilmesi gereklidir:

1. *P(H)*'nin hesaplanabilmesi için hedef dil için bir İDM
2. *P(K|H)*'nin hesaplanabilmesi için bir çeviri modeli
3. Bütün bu olasılık değerlerini kullanarak verilen bir *K* tümcesi için en olası *H* tümcesini üretebilen bir çözücü (decoder)

Bu bileşenlerden istatistiksel dil modeli bileşeni Bölüm 2.3'de anlatılmıştır. Gerekli dil modelleri sadece hedef dil için üretilmek zorunda olduğundan bu dil modellerinin oluşturulması çeviri modelinin üretilmesine göre daha kolaydır.

Çeviri modelinin oluşturulması için, kaynak tümcedeki sözcük yada sözcük öbeklerinin, hedef dilde hangi sözcük yada sözcük öbeklerinin karşılığı olduğu (ürettiği) bilgisi gereklidir. Bu bilgileri içeren çok sayıda tümce üzerinde çeşitli tekniklerle gerçeklenen hesaplamalar sonucunda çeviri modeli hesaplanmaktadır. Bu

amaçla, birbirlerinin çevirisi olan, hedef ve kaynak dildeki büyük miktarda (genellikle milyonlarca tümceden oluşan) metinler önce tümce bazında daha sonra da sözcük/sözcük öbeği bazında paralelleştirilir. Bu işlemlere **tümce hizalama** (sentence alignment), **sözcük hizalama** (word alignment), **sözcük öbeği hizalama** (phrase alignment) adı verilir.

İstatistiksel çevirinin son bileşeni ise çözücüdür. En olası çeviri olan H tümcesinin nasıl bulunacağı matematiksel olarak bilinse de, hedef dildeki olası bütün tümceleri üreterek bunlardan denklem (3.3)'ye göre en olası H tümcesini belirlemek pratik olarak olanaksızdır. Bu amaçla demetli-arama, A^* gibi daha verimli arama yöntemleri kullanılabilir [36].

3.3. Örnek Tabanlı Yöntemler

Örnek tabanlı yöntemler (Example Based Translation), her iki dilde karşılıklı tümceler içeren tümcelerden oluşan bir derlemi kullanarak "örnekseme" yoluyla çeviri ilkesini kullanır [2]. Çalışma ilkesinden dolayı "örneksemeyle çeviri" (translation by analogy) olarak da isimlendirilir. Yöntemin çeviri üzerindeki temel varsayımları şunlardır:

- İnsanlar basit tümceleri derinlemesine dilbilgisi kurallarıyla çevirmezler.
- Aksine, insanların çeviri yaparken ilk adımları, kaynak tümceyi belirli alt öbeklere parçalamaktır. Daha sonra bu öbekleri hedef dile çevirir ve son adımda da bu öbekleri uygun biçimde birleştirerek daha uzun sonuç tümcesini üretir.
- Öbeklerin çevrilmesinde ise daha önceden "akılda kalan" örneklere örnekseme yapılır.

Örneğin aşağıdaki iki çeviriyi ele alalım:

```
A man eats vegetables   ↔    Hito wa yasai o taberu
Acid eats metal         ↔    San wa kinzoku o okasu
```

Bu iki örnek tümceye benzetilerek aşağıdaki girdi tümcesi çevrilmek istensin:

```
He eats potatoes
```

Kuşkusuz çeviri işlemi için bir aktarım sözlüğü gereklidir. Ama buradaki asıl sorun İngilizce ***eat*** eylemi için olası iki Japonca karşılıktan (***taberu*** ve ***okasu***) hangisinin kullanılacağına karar vermektir. Yöntem, doğru karar vererek ***taberu*** eylemini seçer çünkü tümcenin diğer öğeleri ***he*** ve ***potatoes*** sözcükleri, örneklerden ***man*** ve ***vegetables*** sözcüklerine, ***acid*** ve ***metal*** sözcüklerinden anlamsal olarak daha yakındır. Benzer mantıkla aşağıdaki giriş tümcesi için de ***okasu*** eylemi seçilir:

```
Sulfric acid eats iron.
```

Sözcüklerin anlamsal olarak birbirlerine yakınlık ve uzaklıkları, bir sözlük ve kavramlar dizini (thesaurus) kullanılarak bulunur. Kavramlar dizini, sözcüklerin eş/zıt anlamlılarını (synonym/antonym), alt/üst kavramlarını (upper/lower concept) , parça/bütün (part/whole) ilişkinlerini de içeren geniş kapsamlı bir sözlük olarak değerlendirilebilir.

Eğitim derlemindeki tümceler çoklukla birbirinden sadece tek sözcük farklı olacak şekilde seçilir. Bu sayede yöntemin tümcelerin alt parçalarını daha kolay öğrenmesi sağlanır.

```
How much is that red umbrella?↔Ano akai kasa wa ikura desu ka?
How much is that small camera?↔Ano chiisai kamera wa ikura desu ka?
```

Bu örneklerden aşağıdaki bilgiler çıkartılır:

1. `How much is that X? ↔Ano X wa ikura desu ka?`
2. `red umbrella ↔ akai kasa`
3. `small camera ↔chiisai kamera`

Öğrenilen bu bilgiler daha sonraki çevirilerde kullanılmak üzere depolanır. Son gelişmelerle, bu kuralların depolanmadan çalışma anında çıkartılarak kullanılması yoluna gidilmiştir.

Bu yöntem yayınlandıktan sonra Türkçe dahil birçok dilde çalışmalar yapılmıştır [37-39].

3.4. Çeviri Kalitesinin Değerlendirilmesi

Geliştirilen bilgisayarlı çeviri yöntemlerinin ve yöntemler üzerinde yapılan değişikliklerinin sonuçlarının incelenmesi için üretilen sonuçların çıktıların yani çevirilerin doğruluğu ve başarısı ölçülmelidir.

Çeviri kalitesinin ölçülmesi için en basit yol, sistem çıktılarının insanlar tarafından çeşitli yönlerden (üretilen tümcenin akıcılığı, kaynak tümcedeki anlamın aktarılmasındaki doğruluk gibi) puanlanmasıdır. Üretilen çıktıları insanlar kullanacağı için en uygun değerlendirme yöntemi aslında bu olmasına rağmen, hem maliyet açısından çok pahalı hem de hız açısından oldukça yavaştır. Ayrıca aktarım sistemlerinin sürekli geliştirildiği ve her yapılan değişikliğin etkilerini görmek için böyle bir değerlendirmeye gereksinim duyulduğu göz önüne alınırsa bu yöntemin yapılabilirliği oldukça azalmaktadır.

Bazı değerlendirme sistemleri ise başarım ölçütü olarak, sistem tarafından üretilen çevirinin bir çevirmen tarafından düzeltilmesi sürecinin karmaşıklığını ölçme esasına dayanmaktadır. Bu tür yöntemlerin çıkış fikri, bilgisayarlı çeviri sistemlerinin çıktılarının genel olarak insan emeği ile düzeltilerek kullanıldığını dolayısı ile sistemin başarısının, çevirmenin harcadığı çaba ile ölçülebileceği görüşüdür. Bu tür ölçme yöntemleri, çevirmenin harcadığı çabayı, aday çeviri üzerinde tüm düzeltmeleri yapmak için, tuş takımında kaç defa tuşa basıldığı ya da çevirmen tarafından düzeltilen son sürümü ile aday arasındaki en kısa değişim uzaklığı (minimum edit distance) değeri ile orantılı olarak hesaplar.

Değerlendirmede izlenebilecek bir başka yol da otomatik yöntemlerle değerlendirme yapmaktır. Sonraki bölümlerde bu yöntemler kısaca tanıtılacaktır.

3.4.1. BLEU/NIST

BLEU yöntemi, IBM tarafından 2002 yılında geliştirilmiştir [40]. Değerlendirme mantığı, sistem çıktısı aday tümcelerin, çevirmenler tarafından elle çevrilmiş k adet referans çeviri ile olan benzerliğinin ölçülmesine dayanır. Benzerliğin ölçülmesi ise, sistem çıktısındaki sözcüklerin (1-gram) ve sözcük dizilerinin (2,3,4,…-gram), referans çevirilerdeki sözcük ve sözcük dizileri ile eşleştirilmesiyle yapılır. Uygulamada dörtten uzun sözcük dizilerinin eşleştirilmesinin gereksiz olduğu görülmüştür.

Çevirinin doğası gereği bir tümcenin, aynı anlamı taşıyan birden fazla çevirisi olabilir. Sözcük ve ifade seçimlerindeki bu serbestlik derecesi, değerlendirme aşamasında birden fazla referans çeviri kullanılarak çözülmeye çalışılmıştır.

Her n-gram mertebesi için, C derlemi içindeki her S aday tümcesi için hesaplanan **değiştirilmiş kesinlik (modified precision)** değeri p_n şu şekilde bulunur:

$$p_n = \frac{\sum_{S \in C} \sum_{ngram \in S} \text{Adet}_{eşleşen}(ngram)}{\sum_{S \in C} \sum_{ngram \in S} \text{Adet}(ngram)} \quad (3.4)$$

Bu denklemde, çeviri aday tümcesinde yer alan ngram (yani sözcük yada sözcük dizisi), referans çevirilerde birden fazla defa geçse de bir eşleşme olarak sayılır.

BLEU yöntemi ağırlıklı olarak kesinlik (precision) ölçütüne dayanmaktadır. Birden fazla referans çeviri kullanılabildiği için gerigetirim (recall) değerini hesaplamak zordur. Bu nedenle, referans çevirilerden çok daha kısa bir aday çevirinin, yüksek kesinlik değeri sayesinde yüksek BLEU puanları almasını engellemek amacıyla bir **kısalık cezası** (Brevity Penalty) tanımlanmıştır:

$$BP = \begin{cases} 1 & \text{eğer c>r} \\ e^{1-r/c} & \text{eğer c} \leq \text{r} \end{cases} \quad (3.5)$$

Bu denklemde c derlemdeki aday çevirilerin tamamının toplam uzunluğunu, r ise etkin (effective) referans uzunluğunu göstermektedir. Etkin referans uzunluğu, referans tümceler derlemi içerisinde, kendi aday tümcesinin uzunluğuna en yakın olan referansların uzunlukları toplamıdır.

Bu tanımlamalardan sonra BLEU puanı aşağıdaki gibi hesaplanır:

$$BLEU = BP \times \exp(\sum_{n=1}^{N} w_n \log p_n) \quad (3.6)$$

BLEU değeri temel olarak eşleşen n-gram oranlarının geometrik ortalamasının bulunmasıyla hesaplanır ve 0 ile 1 aralığındadır. BLEU puanın 1 olması, aday çevirilerin, referanslardan en az 1 tanesi ile birebir aynı olduğunu göstermektedir.

Yapılan çalışmada, bir deneme kümesindeki tümcelerin çevirilerinin BLEU puanları ile seçilen hakemlerin çevirilere verdikleri puanlar karşılaştırılmış ve BLEU puanları ile bu kişilerin değerlendirmeleri arasında ilinti olduğu gösterilmiştir [40].

NIST yaklaşımı da temel olarak BLEU ile aynı değerlendirme adımlarını izlemesine karşın n-gram eşleşmelerinin geometrik ortalaması yerine aritmetik ortalamasını kullanır ve hesaplanan p_n değerlerini n-gramların sıklıkları ile ilişkilendirilir (daha az sıklığa sahip eşleşme daha önemlidir) [41].

Son yıllarda yapılan çalışmalar sonucunda BLEU değerlendirme sisteminin bazı olumsuz yanları ortaya çıkartılmıştır. Örneğin yüksek BLEU puanlarının, her zaman çevirilerin daha kaliteli olduğunun bir göstergesi olmadığı, tersine BLEU puanlarında artış elde edilerek üretilen çevirilerin kalitesinin yükseltilemeyebileceği ortaya çıkartılmıştır [42]. Ancak BLEU yönteminin otomatik olması ve insan emeği gerektiren değerlendirmelere oranla çok daha ucuz ve hızlı olması gibi nedenlerden dolayı günümüzde BLEU yöntemi yaygın olarak kullanılmaktadır.

Anılan nedenlerden ötürü BLEU yönteminin farklı (en azından istatistiksel-kural tabanlı gibi farklı aktarım yaklaşımları kullanan) sistemlerin başarılarının karşılaştırılmasında kullanılmaması gerektiği, BLEUnun daha çok tek bir sistem üzerinde yapılan ardışık değişikliklerin etkilerini değerlendirmede kullanılmasının uygun olacağı görüşü ağırlık kazanmıştır [42].

3.4.2. F Ölçütü

F-ölçütü, bilgi getiriminde (information retrieval) kullanılan kesinlik ve gerigetirim metriklerinin harmonik ortalaması olarak tanımlanabilir [43]. Bu yöntem, aday tümce ile referans tümce arasında, daha uzun sözcük dizisi eşleşmelerini kayıracak biçimde "en uzun eşleşmeyi" (maximum matching) bulmak üzerine yoğunlaşır. Bu eşleşmenin bulunmasından sonra kesinlik ve gerigetirim değerleri, bulunan bu en uzun eşleşme *EUE* sözcük sayısı ile, sırasıyla aday *A* ve referans *R* tümcelerindeki sözcük sayılarına bölünerek bulunur:

$$\text{Precision}(A|R) = \frac{|\text{EUE}(A,R)|}{|A|} \tag{3.7}$$

$$\text{Recall}(A|R) = \frac{|\text{EUE}(A,R)|}{|R|} \tag{3.8}$$

3.4.3. Meteor

Meteor ölçütü, F-ölçütü'nü birkaç yönden değiştirerek kullanmaktadır [44]. Meteor değerlendirme sisteminde bazı dilbilimsel süreçler[1] değerlendirme aşamasına dahil

[1] İngilizce için Porter Stemmer yöntemi ile eklerin atılarak köklerin elde edilmesi süreci eklenmiştir.

edilerek doğrudan sözcük eşleşmeleri yerine sözcük köklerinin de eşleşmesine olanak tanınmıştır. Ayrıca Meteor yönteminde, gerigetirim değeri üzerinde ağırlaştırma yapan bir harmonik ortalama kullanılır :

$$F_{ort} = \frac{10PR}{R+9P} \tag{3.9}$$

Kesinlik ve gerigetirim değerlerinin sözcük eşleşmesine (1-gram) bağlı olmasından dolayı daha uzun eşleşmeler değerlendirmeye alınmamaktadır. Yöntem, bu açığı kapatmak amacıyla bir ceza katsayısı içermektedir. Bu katsayı hesaplanmadan önce, aday ve referans tümcede birbirlerinin karşılığı olan sözcük grupları (chunks) oluşturulur. Bu sözcük gruplarını oluşturulmasında tek kısıt, hem aday hem de referans tümcede birbirlerinin karşılığı olan sözcüklerin sıralarının grup içinde de aynı kalmasıdır. Örneğin "daha sonra beraber eve gittiler" aday çevirisi ile "daha sonra hep beraber eve gittiler" referans çevirisinde iki grup oluşur : (1) "daha sonra" (2) "beraber eve gittiler". Bu gruplamadan sonra ceza katsayısı ve sonuç puanı aşağıda formüllere göre hesaplanır:

$$Ceza = 0,5 \times \left(\frac{|gruplar|}{|eşleşen\ sözcükler|} \right)^3 \tag{3.10}$$

$$METEOR = F_{ort} \times (1 - Ceza) \tag{3.11}$$

Meteor yönteminin en önemli olumsuz yönü, birden fazla referans çeviri olduğunda ortaya çıkmaktadır. Her referans çeviri için bir puan hesaplanarak en yüksek puan çıktı olarak kullanılır. Oysa bazı durumlarda çevirinin bir bölümü (örneğin özneyi oluşturan ad öbeği) referanslardan bir tanesinin bir bölümü ile eşleşirken, çevirinin başka bir bölümü (örneğin eylem öbeği) başka bir referans ile eşleşebilir. Yöntemin bir başka bir olumsuz tarafı ise puanlamada kullanılan katsayıların değerlerinin belirlenmesidir. Geçerli katsayılar deneme-yanılma yöntemi ile bulunduğundan en uygun katsayılar olup olmadığı şüphelidir.

4. AKRABA ve BİTİŞKEN DİLLER ARASINDA ÇEVİRİ

4.1. Giriş

Akraba diller arasındaki yapısal benzerlikler yardımı ile, bu diller arasında bilgisayarlı çevirinin gerçeklenmesi, farklı dil aileleri arasında çeviri yapmaktan, en azından sezgisel olarak, daha kolay görünmektedir. Tamamen farklı dil ailelerinde sınıflandırılan diller arasında çeviri yapmanın zorluğu, M. Nagao'nun tarafından aşağıdaki sözlerle ifade edilmiştir [2] :

> "Avrupa dilleri arasında belirli bir ortak taban bulunur, dolayısıyla bu diller arasında çeviri yaparken, tümcedeki ifadeler yapısal olarak büyük değişikliklere uğramazlar. Oysa İngilizce ve Japonca gibi tamamen farklı iki dil arasında çeviri yapmanın birçok zorluğu vardır. Bazen aynı anlam tamamen farklı yapılarla ifade edilir. Her iki dilde bu yapıların karşılıklarının doğru bir eşleşmesi her zaman bulunmayabilir."

Bu noktadan hareketle, akraba diller arasında çeviri yapmanın daha kolay olacağı sonucu kendiliğinden doğmaktadır.

Bu tez çalışması kapsamında akraba diller arasında bilgisayarlı metin çevirisi için istatistiksel ve bilgi tabanlı yöntemlerin beraber kullanıldığı karma modeller önerilmiştir. Önerilen bu karma modeller sayesinde hem istastiksel yöntemlerin en maliyetli koşulu olan hizalanmış eğitim kümesi gereksinimi ortadan kaldırılmış olmakta hem de yüksek başarılar elde eden istatiksel yöntemlerin sunduğu getirilerden faydanılmış olunmaktadır.

Geliştirilen modeller, temelde bitişken yapıdaki akraba diller için tasarlanmıştır. Çalışma kapsamında önerilen modeller Türk dil ailesindeki dillerin birbirine çevrilmesi amacıyla incelenmiş, seçilen bir dil çifti için uygulama gerçeklenerek modellerin başarımı ortaya konulmuştur. Ancak geliştirilen modeller Türk dillerine özgü olmayıp, dilden bağımsız düşünülmüş, akraba ve bitişken olan tüm dil çiftleri için kullanılabilir niteliktedir.

Modellerin çıkış noktası, Bölüm 3.2'de tanıtılan istatistiksel çeviri yöntemlerinin temel denklemidir. Bu denklem aşağıdaki tekrar verilmiştir :

$$H = \underset{H \in \text{Hedef Dil}}{\arg\max} \underbrace{P(K \mid H)}_{\text{çeviri modeli}} \underbrace{P(H)}_{\text{dil modeli}} \tag{4.1}$$

İki bileşenden oluşan bu denklemin dil modeli bileşeni, sadece hedef dil için hazırlandığından, çeviri modeline göre daha kolay oluşturulabilir. Çeviri modelinin oluşturulması için çok sayıda hizalanmış tümce çiftlerine gereksinim duyulmaktadır. Ancak günümüzde dahi her dil çifti için birbirlerinin çevirisi olan hizalanmış tümcelerin yeterli miktarlarda bulunması mümkün olmamaktadır. Amacımız, bu olumsuz koşullarda da istatistiksel çevirinin kullanılabilir hale gelmesi için, istatistiksel çevirideki bu "çeviri modeli olasılık dağılımı" yerine kullanılabilecek bir modelin oluşturulmasıdır.

Kuramsal açıdan denklem (4.1), hedef dildeki bütün tümceler içerisinden, çeviri ve dil modellerine göre en yüksek olasılığa sahip tümcenin bulunması anlamına gelmektedir.

Ancak bir dildeki olası tümcelerin sayısının sonsuz olması nedeni ile uygulamada çeviriyi üreten çözücü, hedef dildeki *H* tümcesini adım adım (sözcük ya da sözcük öbeği adımları ile) üretmeye başlar [36]. Her adımda, çeviri modeline ve dil modeline göre en yüksek olasılığa sahip seçenek ya da seçeneklerden devam ederek sonunda tüm çeviri tümcesini oluşturur. Bu çalışma düzeninde çeviri modeli, kaynak tümcenin sözcüklerinin/sözcük sözcüklerinin ya da sözcük öbeklerinin karşılığı olabilecek tümceleri (olasılıklarına göre) oluştururken, dil modeli bileşeni de oluşan bu tümceler içinden hedef dil için en uygununu bulmaya çalışır. Bir anlamda "*çeviri modeli*", hedef dildeki tüm tümcelerde arama yapmak yerine, kaynak tümcenin çevirisi olabilecek tümceleri olasılıklarına göre seçerek aramayı yönlendirmektedir.

Bu tez çalışmasında önerilen yaklaşım, akraba diller, örneğin Türk dilleri, arasında çeviri söz konusu olduğunda, olasılık dağılımı esasına göre çalışan "çeviri bileşeninin", bilgi tabanlı çalışan "aktarım fonksiyonu" ile değiştirilerek istatistiksel dil modeli ile beraber kullanılması yönündedir. Bu yaklaşım sezgisel olarak, dil modeline göre en uygun tümceyi, "*çeviri modelinin yönlendirmesi ile hedef dildeki bütün tümceler kümesinde aramak yerine, aktarım fonksiyonu tarafından aktarılan sözcük/sözcük öbekleri ile oluşturulabilecek tüm olası tümceler kümesinde aramak"*

olarak yorumlanabilir. Bu sayede, Türk dilleri gibi birbirleri ile benzer akraba diller arasında kullanılabilecek, bilgi tabanlı yöntemler ve istatistik tabanlı yöntemlerin birleşimi olan karma (hibrid) bir çeviri modeli önerilmiştir.

Önerilen bu modele göre denklem (4.1)'in güncellenmiş hali aşağıdaki gibidir:

$$\hat{H} = \underset{H \in \underset{\text{aktarım fonksiyonu}}{\text{F(K)}}}{\arg\max} \underbrace{P(H)}_{\text{dil modeli}} \tag{4.2}$$

Önerdiğimiz çeviri modeli de iki bileşenden oluşmaktadır. Aktarım fonksiyonu, *K* tümcesinin karşılığı olabilecek tüm tümceleri üreten bir fonksiyon (transfer function) olarak görev yaparken, dil modeli ise klasik anlamda kullanılarak üretilen karşılıklar arasından hedef dile göre en yüksek olasılık değerine sahip tümcenin seçilmesini sağlar.

Ancak önerilen bilgisayarlı çeviri yöntemi ile istatistiksel çeviri yöntemi arasında vurgulanması gereken önemli bir farklılık bulunmaktadır. İstatistiksel çeviri sisteminde yer alan çeviri modeli, kaynak dildeki tümcenin karşılığı olabilecek aday tümceler kümesini üretirken aynı zamanda bunlar için birer olasılık değeri de atamaktadır. Bu olasılık değeri, dil modeli olasılığı ile birleştirilerek en yüksek olasılıklı çevirinin belirlenmesinde rol oynar. Oysa bizim önerdiğimiz aktarım modelindeki aktarım fonksiyonu, sadece kaynak tümcenin karşılığı olabilecek tümceler üretmektedir, bunlara herhangi bir olasılık değeri atanmamaktadır. Bu tümcelerden en uygun olanı ise dil modeli bileşeni tarafından en yüksek olasılıklı tümcenin seçilmesi ile belirlenir.

Seçilen dil çiftinin bitişken olması durumunda aktarım fonksiyonu ve dil modeli bileşeni, özelleştirilerek kullanılmalıdır. Sonraki bölümlerde önerilen aktarım fonksiyonu ve dil modeli türlerinin ayrıntıları ele alınmıştır.

4.2. Aktarım Fonksiyonu Modelleri

Bu araya birkaç tümce yazalım

4.2.1. Aktarım Modeli 0 – Temel Model

Akraba diller söz konusu olduğunda, diller arasındaki benzerlikleri kullanarak çeviri sürecini basitleştirmenin en kolay yolu, sözcük bazında çalışan doğrudan aktarım modelinin kullanılmasıdır. Özellikle sözdizimi açısında büyük farklılıklar göstermeyen akraba diller arasında daha uygun olan bu doğrudan aktarım modeli, bitişken diller için, sözcük kökleri ile birlikte biçimbirimsel yapıların da aktarılmasını sağlayacak biçimde değiştirilmiştir. Sonuçta oluşan temel aktarım modelinin matematiksel açıklaması aşağıda verilmiştir.

K, toplam *N* adet sözcükten oluşan $(k_1 k_2 ... k_N)$ kaynak dilde bir tümce olsun.

$$K = k_1 k_2 ... k_N = k_1^N \tag{4.3}$$

Bitişken diller söz konusu olduğunda, her bir sözcüğün hedef dile aktarılması için öncelikle biçimbirimsel çözümlemesinin yapılması, sözcük kökünün ve diğer biçimbirimsel yapıların bulunması gereklidir. Buna göre biçimbirimsel çözümleme aşaması, girişi kaynak dilde yüzeysel biçimdeki sözcük k_i, çıkışı ise bu sözcüğün olası tüm biçimbirimsel çözümlemelerini içeren bir küme olan $C(k_i)$ çözümleme fonksiyonu ile modellenir.

$$C(k_i) = \left\{ c_{i1}, c_{i2}, ..., c_{in_i} \right\} \tag{4.4}$$

Burada n_i , k_i sözcüğü için üretilen biçimbirimsel çözümlemelerin toplam sayısıdır ve $n_i \geq 1$ şeklinde alttan sınırlıdır[2]. Üretilen her bir biçimbirimsel çözümleme, kök ve bu köke eklenen değişken sayıda[3] biçimbirimsel özelliklerden oluşur:

$$c_{ij} = kok_{ij} + b_{ij1} + ... + b_{ijk} + ... + b_{ijm_i} \tag{4.5}$$

Biçimbirimsel özellikler b_{ijk} ve sözcük kökleri kok_{ij} aktarılması $A(c_{ij})$ aktarım fonksiyonu ile sağlanır. Bu aktarım fonksiyonu giriş değeri olarak, biçimbirimsel bir

---

[2] Biçimbirimsel çözümleyicinin başarısız olarak çıktı üretemediği durumların olmadığı varsayılmıştır. Uygulamada, Türkçe için 1 milyon sözcüklük derlemde bir sözcük için ortalama n_i sayısı 1,75'tir.

[3] Uygulamada, Türkçe'de, çözümleme başına düşen (kök dışında) biçimbirimsel özellik sayısı 4,36'dır.

çözümleme c_{ij}'yi almakta, çıkış olarak ise sözcük kökünün ve biçimbirimsel özelliklerin hedef dile aktarılmış halini üretmektedir:

$$A(c_{ij}) = \left\{ a_{ij1}, ..., a_{ijk}, ..., a_{ijn_{ij}} \right\} \tag{4.6}$$

Sözcük köklerinin çevrilmesinde birden-çoğa ilişki olduğu için bir çözümlemeye karşılık birden fazla çeviri oluşabilmektedir. Dolayısı ile A fonksiyonu çok-değerli çokdeğerli (multi-valued) bir fonksiyon olarak işlev görmektedir. Bu koşullarda üretilen sözcük sayısı $n_{ij} \geq 1$ olacaktır[4]. Kaynak tümcedeki k_i sözcüğünün c_j çözümlemesine karşılık olarak üretilen her bir a_{ijk} çıktısı, çözümleme ile benzer yapıya sahiptir:

$$a_{ijk} = kokh_{ijk} + bh_{ijk1} + bh_{ijk2} + ... + bh_{ijkm_{ijk}} \tag{4.7}$$

Burada *kokh* hedef dildeki kökü, *bh* ise hedef dildeki biçimbirimsel özellikleri göstermektedir.

Bütün bu tanımlamalardan sonra, temel amacımız olan transfer fonksiyonun tanımı yapılabilir. Aslında tanımlanması amaçlanan aktarım fonksiyonu F, bir fonksiyon değildir. F, bir bağıntı olarak tanımlanmalıdır. Hedef dildeki tüm tümceler üzerinde tanımlı olan bu bağıntı, yalnızca "kaynak dildeki sözcüklerin hedef dildeki karşılıklarından oluşan bir dizi sözcüğü içeren" bir alt kümedir:

$$\begin{aligned} F(K) = F(k_1^N) &= \bigcup_{c_{1j} \in C(k_1)} A(c_{1j}) \times \bigcup_{c_{2j} \in C(k_2)} A(c_{2j}) \times ... \times \bigcup_{c_{Nj} \in C(k_N)} A(c_{Nj}) \\ &= \prod_{i=1}^{N} \bigcup_{c_{ij} \in C(k_i)} A(c_{1j}) \end{aligned} \tag{4.8}$$

Eğer $f_i(K)$, $F(K)$ bağıntısının *i.* elemanı olarak tanımlanırsa, geliştirilen aktarım modelimizin amacı, olası bütün çeviriler içerisinden en yüksek olasılıklı $\hat{H}_B$'yi

[4] Sözcük kökünün karşılığının aktarım sözlüğünde bulunmadığı durumlarda hiçbir çıktı üretmemek yerine, kaynak dildeki sözcük kökü doğrudan hedef dile kopyalanır. Bu sayede $n_{ij} \geq 1$ koşulu her zaman sağlanmış olur.

bulmak olarak ifade edilebilir. Buradaki alt indis *B*, oluşan tümcenin sözcüklerinin yüzeysel biçim yerine yapısal biçimde olduğunu belirtmektedir. En yüksek olasılıklı tümcenin bulunması ise, *E* eğitim derlemi üzerinde eğitilen bir *L(E)* dil modeli ile sağlanır:

$$\hat{H}_B = \underset{f_i(K) \in F(K)}{\arg\max}\, p\left(f_i(K) \mid L(E) \right) \tag{4.9}$$

Aktarım modelinin son aşaması ise hedef dildeki biçimbirimsel üretici tarafından, dönüştürülen sözcük kökleri ve biçimbirimsel yapılardan yüzeysel biçimlerin elde edilmesidir. Bu üretim aşaması ise bir *U* fonksiyonu ile temsil edilir:

$$\hat{H} = U(\hat{H}_B) = h_1 h_2 ... h_M \tag{4.10}$$

Modelin son çıktısı olan $\hat{H}$, kaynak dildeki sözcüklerin, hedef dildeki karşılıklarının sıralandığı tümceyi göstermektedir. Aktarım aşamasında birden-çoğa birden çoğa bir yöntem izlendiğinden, oluşan çeviri tümcesinin sözcük sayısı $M \geq N$'dir.

4.2.2. Aktarım Modeli I

Temel modelin en önemli olumsuzluğu, sözcük bazında sadece bire-bir ya da birden-çoğa aktarım yapılmasına izin vermesidir. Temel modelin bu kısıtlaması sonucu, kaynak tümcede birden çok sözcükle ifade edilen yapılar hedef dile doğru aktarılamayacaktır. Bunu gidermek amacı ile temel modele çoktan-çoğa (many-to-many) aktarım yapmak üzere bir takım eklemeler yapılarak Aktarım Modeli I elde edilmiştir. Bu eklemelerle öncelikle çoklu sözcük grupları (ÇSG) belirlenmiş, daha sonra bu gruplar uygun şekilde hedef dile aktarılmıştır.

Bitişken diller için çoklu sözcük gruplarının bulunma süreci, İngilizce, Çince gibi yalıtımlı (isolating) ya da yalıtımlıya yakın dillerdeki kadar basit değildir. Bunlar ve benzeri dillerde basit bir liste kullanılarak çoklu sözcük grupları belirlenebilirken, Türkçe, Fince, Japonca, Macarca gibi bitişken dillerde çoklu sözcük gruplarının bileşenleri çeşitli biçimbirimsel değişikliklere uğrayabilirler [45]. Bu değişiklikler, ÇSG'lerin, basitçe bir listeden bakılarak belirlenmesini engellemektedir. Sonuçta Sonuç olarak, bitişken dillerde ÇSG'lerin bulunması için tümcedeki sözcüklerin kökleri ve diğer biçimbirimsel özellikleri gibi daha ayrıntılı bilgilerle, düzenli

ifadeler ya da sonlu durumlu dönüştürücüler gibi daha karmaşık araçlara gerek duyulur.

Temel model tanıtılırken verilen matematiksel altyapıya bağlı kalınarak ÇSG'lerin işlenmesi ile ortaya konulan yeni modelin matematiksel ifadesi aşağıdaki gibi kurulmuştur.

ÇSG'leri, bir ya da birden fazla sözcüğe ait biçimbirimsel çözümleme kümeleri arasından belirli bir yönteme ya da kural dizisine göre seçilen elemanlardan oluşan sıralı eşleşmeler (ordered pairs) olarak adlandırılabiliriz. Örneğin aşağıda bir *K* tümcesinin ardışıl üç sözcüğü (k_i k_{i+1} k_{i+2}) için biçimbirimsel çözümleme sonuçları bulunmaktadır:

$$\begin{aligned} C(k_i) &= \left\{ c_{i,1}, c_{i,2}, \ldots, \mathbf{c_{i,x}}, .., c_{i,n_i} \right\} \\ C(k_{i+1}) &= \left\{ c_{i+1,1}, c_{i+1,2}, \ldots, \mathbf{c_{i+1,y}}, .., c_{i+1,n_{i+1}} \right\} \\ C(k_{i+2}) &= \left\{ c_{i+2,1}, c_{i+2,2}, \ldots, \mathbf{c_{i+2,z}}, .., c_{i+2,n_{i+2}} \right\} \end{aligned} \tag{4.11}$$

Varsayalım ki ÇSG bulucu kurallar, bu üç sözcüğün çözümlemeleri içerisindeki $\boldsymbol{c_{i,x}}$, $\boldsymbol{c_{i+1,y}}$ ve $\boldsymbol{c_{i+2,z}}$ çözümlemelerinin bir ÇSG oluşturduğunu belirlesin. Bu durumda bu üç elemanlı sıralı eşleşmeler $\boldsymbol{(c_{i,x}, c_{i+1,y}, c_{i+2,z})}$, *G(K)* kümesinin bir elemanı olur. Bu durumda *G(K)* aşağıdaki kümeler üzerinde tanımlı bir bağıntı olmaktadır:

$$G(K) \subseteq \prod_{i=1}^{N} C(k_i) \tag{4.12}$$

Tümceyi oluşturan bütün sözcüklerin tüm çözümlemelerinin kartezyen çarpımı içerisinde arama yapılarak, kurallara uyan sıralı çiftler *G(K)* bağıntısının elemanı olarak belirlenir. Ancak ifade bu şekli ile matematiksel olarak yanlıştır. Çünkü kartezyen çarpımı ile oluşturulan kümenin elemanlarının hepsi, mutlak olarak *N* sözcükten oluşmalıdır. Bu ise şu anlama gelmektedir: sadece *N* sözcükten oluşmuş ÇSG'leri işlenebilir, yukarıda örnekteki $\boldsymbol{(c_{i,x}, c_{i+1,y}, c_{i+2,z})}$ gibi üç elemanlı bir sıralı eşleşme girdisi *G(K)* kümesinin elemanı olamaz.

Bunu düzeltmek için *G(K)* bağıntısının üzerinde tanımlı olduğu kümelere etkisiz bir eleman eklemek yeterli olacaktır:

$$G(K) \subseteq \prod_{i=1}^{N} \left(C(k_i) \cup \{\varepsilon\} \right) \tag{4.13}$$

ÇSG belirleyici kuralların, ε girdisini boş katar olarak yorumlayacağı ve göz ardı edeceği düşünüldüğünde, $(c_{i,x}, c_{i+1,y}, c_{i+2,z})$ girdisi artık $(\varepsilon,\varepsilon,\ldots, c_{i,x}, c_{i+1,y}, c_{i+2,z}, \ldots,\varepsilon,\varepsilon)$ biçimine dönüşerek *G(K)* kümesine eklenebilir.

Sözcük sözcük aktarma yapılırken, eğer sıradaki sözcüğün herhangi bir çözümlemesi c_{ij}, *G(K)* içerisindeki ÇSG'lerin bir parçası ise, bu sözcüğün hiçbir çözümlemesi aktarılmaz. Ancak eğer c_{ij}, bu ÇSG'nin son sözcüğü ise, c_{ij} yerine bu ÇSG birleştirilerek aktarım fonksiyonuna gönderilir. Buna göre yukarıda verilen $(c_{i,x}, c_{i+1,y}, c_{i+2,z})$ örneğinin aktarılma süreci aşağıdaki gibidir:

$$\begin{aligned}
C(k_i) &= \left\{ c_{i,1}, c_{i,2}, ..., \mathbf{c_{i,x}}, .., c_{i,n_i} \right\} \\
E(C(k_i)) &= \left\{ \varnothing,\ \varnothing, ..., \varnothing, ..., \varnothing \right\} \\
C(k_{i+1}) &= \left\{ c_{i+1,1}, c_{i+1,2}, ..., \mathbf{c_{i+1,y}}, .., c_{i+1,n_{i+1}} \right\} \\
E(C(k_{i+1})) &= \left\{ \varnothing,\quad \varnothing,\quad ..., \varnothing,\quad ..., \varnothing \right\} \\
C(k_{i+2}) &= \left\{ c_{i+2,1}, c_{i+2,2}, ..., \mathbf{c_{i+2,z}}, \qquad .., c_{i+2,n_{i+2}} \right\} \\
E(C(k_{i+2})) &= \left\{ \varnothing,\quad \varnothing,\quad ..., \mathbf{B}\left(\mathbf{c_{i,x}}, \mathbf{c_{i+1,y}}, \mathbf{c_{i+2,z}}\right),\quad ..., \varnothing \right\}
\end{aligned} \tag{4.14}$$

Bu çalışma düzenini sağlayan *E* fonksiyonunun tanımı aşağıda verilmiştir:

$$E(c_{ij}) = \begin{cases} c_{ij} & eğer\ (\forall j : 1 \le j \le n_i)(\forall p : 1 \le p \le N)\ c_{ij} \ne x_p & (1) \\ \varnothing & eğer\ (\exists j : 1 \le j \le n_i)(\forall p : 1 \le p \le N)\ c_{ij} = x_p \wedge x_{p+1} \ne \varepsilon & (2) \\ B(X) & eğer\ (\exists j : 1 \le j \le n_i)(\forall p : 1 \le p \le N)\ c_{ij} = x_p \wedge x_{p+1} = \varepsilon & (3) \end{cases} \tag{4.15}$$

Denklem (4.15)'de yer alan x_p, $X \in G(K)$ sıralı eşleşmesinin *p.* elemanıdır. *B* fonksiyonu ise *X* sözcük dizisini, geçerli bir biçime getirmek için uygun şekilde birleştirerek tek bir kök ve uygun biçimbirimsel özellikleri içeren yapıya dönüştüren bir birleştirme fonksiyonudur.

E fonksiyonun üzerinde biraz açıklama yapmak uygun olacaktır. Fonksiyonun (1). alt tanım aralığında, *K* tümcesinin *i.* sözcüğü k_i'nin *j.* çözümlemesi c_{ij}'nin aktarılıp aktarılmayacağına karar verilir. Eğer k_i'ye ait çözümlemelerden hiçbirisi, *G(K)*'da belirlenen ÇSG yapılarının herhangi birisinin bileşeni olarak geçmiyorsa, c_{ij} olduğu gibi çıkış olarak üretilir. (2) ile numaralandırılmış alt tanım aralığı ise, eğer k_i

sözcüğünün herhangi bir çözümlemesi, *G(K)*'daki herhangi bir ÇSG'nin son bileşen ($x_{p+1} \neq \varepsilon$) dışındaki bir bileşeni ise , k_i'ye ait bütün çözümlemelerin göz ardı edileceğini söylemektedir. Son tanım aralığı (3) bölgesinde ise, k_i'ye ait bir çözümleme, *G(K)* bağıntısındaki herhangi bir ÇSG'nin son sözcüğü ise ($x_{p+1} = \varepsilon$), c_{ij} yerine ÇSG'nin tamamı (*X*) *B* fonksiyonu tarafından dönüştürülerek üretilir.

ÇSG'lerin aktarılması için bu tanımlamalar yapıldıktan sonra, kaynak tümcenin olası bütün karşılıklarını üreten transfer fonksiyonun denklemi (4.8), aşağıdaki gibi değiştirilir:

$$F(K) = F(k_1^N) = \bigcup_{c_{1j} \in C(k_1)} A\left(E\left(c_{1j}\right)\right) \times \bigcup_{c_{2j} \in C(k_2)} A\left(E\left(c_{2j}\right)\right) \times \ldots \times \bigcup_{c_{Nj} \in C(k_N)} A\left(E\left(c_{1N_j}\right)\right)$$
$$= \prod_{i=1}^{N} \bigcup_{c_{ij} \in C(k_i)} A\left(E\left(c_{1j}\right)\right) \tag{4.16}$$

Dil modelini kullanarak en yüksek olasılıklı tümcenin seçildiği bundan sonraki denklemlerde herhangi bir değişme olmaz.

4.2.3. Aktarım Modeli II

Geliştirilen modellerdeki bir diğer eksiklik de aktarım kurallarının sözcük bazında işlem görmesidir. Akraba diller arasında çeviri yapılsa bile, sözcükler arası ilişkiler her zaman bulunur. Çeviri modelinin başarısının arttırılabilmesi için bu ilişkiler göz önüne alınarak aktarım yapılmalıdır. Örneğin bazı Türk dilleri arasında çeviri yaparken, ortaçların, niteledikleri isimden bazı biçimbirimsel özellikleri alması gerekmektedir. Bu ve buna benzer durumları başarılı çevirebilmek için tümce genelinde işlem gören bir takım aktarım kuralları tanımlanmalıdır. Tümce genelinde çalışan aktarım kuralları, tümcedeki sözcüklerin biçimbirimsel bilgilerini kullanabileceği gibi bazı kurallar da sözcüklerin yüzeysel biçimlerine[5] gerek duyabilir.

[5] Özellikle yazımsal (ortagraphic) kurallar bu sınıfa girmektedir. Örneğin Türkçe'de sözcüklerden ayrı yazılan ama bir önceki sözcüğün son seslisine göre ünlü uyumuna uyan –de bağlacı veya –mi soru eki gibi ekleri doğru şekilde üretebilmek için sözcüklerin yüzeysel biçimlerine gerek duyulur.

Ancak mevcut aktarım fonksiyonu *A*, sadece sözcük kökleri ve sözcüğe ait biçimbirimsel yapıların aktarımı sağlamaktadır. Bunu geliştirmek üzere denklem (4.10) aşağıdaki gibi değiştirilmiştir:

$$\hat{H} = S_Y\left(U\left(S_B\left(\hat{H}_B\right)\right)\right) = h_1 h_2 ... h_M \tag{4.17}$$

Bu denklemde, hedef dilde oluşturulan tümceler üzerinde işlem gören bir S_B fonksiyonu tanımlanmıştır. Bu fonksiyona, giriş olarak yapısal gösterimde sözcüklerden oluşmuş tümceler kümesi gelir. Fonksiyon, her bir tümce üzerinde, sözcükler arasında tanımlanan kurallara uygun olarak aktarımı gerçekleştirilir. Tümcedeki sözcüklerin yüzeysel biçimlerine gerek duyarak yapılan değişiklikler ise S_Y fonksiyonu modellenmiştir.

4.3. Bitişken Diller İçin İDM Oluşturulması

İngilizce, Almanca gibi dillerden farklı olarak, Türkçe için dil modelleri oluşturulurken sözcüklerin yüzeysel biçimlerinin kullanılması, Türkçenin türetken ve çekimli yapısından dolayı seyrek veri sorununa yol açmaktadır. Bu yüzden eğitim verisi olarak sözcüklerin yüzeysel biçimleri yerine, sözcüklerin köklerinin ve diğer bazı biçimbirimsel özelliklerin kullanılması yoluna gidilmiştir.

Yüzeysel biçim yerine, sözcüklere ait biçimbirimsel çözümleme sonuçlarının tamamının kullanılarak bir İDM oluşturulması durumunda, gene seyrek veri sorunu oluşmaktadır. Seyrek veri sorununu azaltmak için, biçimbirimsel çözümlemedeki tüm etiketler yerine bunların gruplanarak kullanılması fikri ortaya çıkmıştır [46]. Örneğin Türkçe'deki her sözcük, kök ve bir veya birden fazla çekim grubundan oluşmaktadır. Çekim grupları birbirlerinden ***^DB*** (derivation boundary) ile ayrılmaktadır [47]:

$$\text{kök+ÇG}_1\text{^DB+ÇG}_2\text{^DB+...^DB+ÇG}_n$$

Burada ÇG_i, sözcük türü ve çekim özelliklerini de içeren ilgili çekim grubunu ifade etmektedir. Örnek olarak aşağıda bir biçimbirimsel çözümleme sonucu verilmiştir:

```
yararlanmanın : yarar+Noun+A3sg+Pnon+Nom            ÇG1
                  ^DB+Verb+Acquire+Pos              ÇG2
                  ^DB+Noun+Inf2+A3sg+Pnon+Gen       ÇG3
```

Bu örnekte, isim türlü ***yarar*** sözcüğünün sözcük türü, ***+lan*** yapım eki ile önce eyleme daha sonra da ***+ma*** mastar eki ile de tekrar isme dönüşmüştür. Bu dönüşme

süreci içerisinde oluşan her sözcük türünün de kendisine ait çekim özellikleri bulunabilir. Türetilmiş bir sözcüğün etkin sözcük türü, son ÇG'nin sözcük türü olarak kullanılır (örneğin etkin sözcük türü "isim"dir).

Tablo 4-1'de, 1 M sözcükten oluşan bir derlem üzerinde gözlenen, kök hariç bütün etiketlerin bulunduğu tam çözümlemelerin ve ÇG'lerin sayıları verilmiştir [46]. Bir köke eklenebilecek ek sayısının sınırsız olmasına karşın, derlem üzerinde yapılan sayıma göre 10.531 farklı tam çözümlemeye rastlanmıştır. Tam çözümlemeler ÇG'lere ayrılarak ÇG'ler sayıldığı zaman ise 2.194 farklı ÇG'ye rastlanmıştır. Bu sonuçlar, ise seyrek veri sorunun bir miktar indirgendiği ortaya koymaktadır.

Tablo 4-1: Derlemde gözlenen tam çözümleme ve çekim grubu sayıları

	Kuramsal Üst Sınır	**Gözlenen Adet**
Tam Çözümleme	∞	10.531
Çekim Grubu	9.129	2.194

Sadeleştirme açısından yapılan bir başka genelleme de ÇG'lerden oluşan türetilmiş bir sözcüğün sözdizimsel açıdan bağlantısının, son ÇG'den çıkarak sonraki sözcüklerin ÇG'lerinden herhangi bir tanesine bağlanması şeklinde ifade edilir [47].

Bu bölümde, türetme ve çekim özelliklerine sahip bitişken diller için, seyrek veri sorunundan en az etkilenecek şekilde dilin farklı özelliklerini modelleyen farklı İDM türleri önerilmiştir.

4.3.1. İDM Tip-I – Kök

Bu tip dil modeli, sözcük köklerinin n-gram olasılıklarından oluşmuştur. Gerçeklenen ön bir işlemle, eğitim derlemindeki girdilerin, sözcük kökü dışındaki tüm biçimbirimsel özellikleri silinerek tip-I İDM için yeni bir eğitim derlemi oluşturulmuştur.

Tablo 4-2 : İDM Tip-I için örnek eğitim tümcesi

Sözcük **Biçimbirimsel Çözümlemesi**	**İDM Eğitim Verisi**
Müzik **müzik**+Noun+A3sg+Pnon+Nom	müzik

dünyasının **dünya**+Noun+A3sg+P3sg+Gen	dünya
tanınmış **tanı**+Verb^DB+Verb+Pass+Pos+Narr+A3sg	tanı
isimleri **isim**+Noun+A3pl+P3sg+Nom	isim
yeni **yeni**+Adj	yeni
yılı **yıl**+Noun+A3sg+Pnon+Acc	yıl
çalışarak **çalış**+Verb+Pos^DB+Adverb+ByDoingSo	çalış
karşıladı **karşıla**+Verb+Pos+Past+A3sg	karşıla

4.3.2. İDM Tip-II – Son Sözcük Türü

Sadece sözcük türlerinden oluşan İDM tipidir. Türetilmiş sözcükler için son çekim grubunun sözcük türü kullanılmıştır. Sözcük türü sayısının az olmasından dolayı yüksek dereceli tip-II İDM'leri oluşturulabilmektedir.

Tablo 4-3 : İDM Tip-II için örnek eğitim tümcesi

Sözcük Biçimbirimsel Çözümlemesi	**İDM Eğitim Verisi**
Müzik müzik+**Noun**+A3sg+Pnon+Nom	Noun
dünyasının dünya+**Noun**+A3sg+P3sg+Gen	Noun
tanınmış tanı+Verb^DB+**Verb**+Pass+Pos+Narr+A3sg	Verb
isimleri isim+**Noun**+A3pl+P3sg+Nom	Noun
yeni yeni+**Adj**	Adj
yılı yıl+**Noun**+A3sg+Pnon+Acc	Noun
çalışarak çalış+Verb+Pos^DB+**Adverb**+ByDoingSo	Adverb
karşıladı karşıla+**Verb**+Pos+Past+A3sg	Verb

Bu tip İDM ile sözdizimsel yapı, farklı bir biçimde modellenmiş olur. Örneğin 4. dereceden tip-II İDM'ye göre aşağıdaki iki tümcenin olasılıkları karşılaştırılırsa, gerçeğe uygun olarak (4.18)'deki tümcenin olasılığının daha fazla olduğu görülür:

$$P(\text{Büyük ev zor temizlenir.}) \approx P(\text{Adj Noun Adverb Verb}) = 1{,}383\text{x}10^{-4} \quad (4.18)$$

$$P(\text{Temizlendi ev zor büyük.}) \approx P(\text{Verb Noun Adverb Adj}) = 6{,}909\text{x}10^{-7} \quad (4.19)$$

4.3.3. İDM Tip-III – Son Çekim Grubu

Sadece son ÇG'ler kullanılarak oluşturulmuş İDM tipidir. Tip-II İDM, tümce sözdizimi ile ilgili bir modelleme yapmasına karşın aynı sözcük türüne sahip çözümlemeleri ayıklama noktasında yetersiz kalmaktadır. Bu amaçla, tip-II İDM'de son çekim grubunda bulunan sözcük türüne ek olarak son ÇG'deki tüm biçimbirimsel özellikler kullanılarak tip-III İDM oluşturulmuştur.

Tablo 4-4 : Tip-III İDM için örnek eğitim tümcesi

Sözcük **Biçimbirimsel Çözümlemesi**	**İDM Eğitim Verisi**
Müzik müzik+**Noun+A3sg+Pnon+Nom**	Noun+A3sg+Pnon+Nom
dünyasının dünya+**Noun+A3sg+P3sg+Gen**	Noun+A3sg+P3sg+Gen
tanınmış tanı+Verb^DB+**Verb+Pass+Pos+Narr+A3sg**	Verb+Pass+Pos+Narr+A3sg
isimleri isim+**Noun+A3pl+P3sg+Nom**	Noun+A3pl+P3sg+Nom
yeni yeni+**Adj**	Adj
yılı yıl+**Noun+A3sg+Pnon+Acc**	Noun+A3sg+P3sg+Nom
çalışarak çalış+Verb+Pos^DB+**Adverb+ByDoingSo**	Adverb+ByDoingSo
karşıladı karşıla+**Verb+Pos+Past+A3sg**	Verb+Pos+Past+A3sg

4.3.4. İDM Tip - IV – Kök + Son Sözcük Türü

Tip-IV İDM, çözümlemede yer alan sözcük kökü ile son ÇG'deki sözcük türü ile oluşturulur. Bu anlamda tip-I ile tip-II İDM birleşimi olarak yorumlanabilir.

Tablo 4-5 : Tip-IV İDM için örnek eğitim tümcesi

Sözcük **Biçimbirimsel Çözümlemesi**	**İDM Eğitim Verisi**
Müzik **müzik**+**Noun**+A3sg+Pnon+Nom	müzik+Noun

dünyasının **dünya**+**Noun**+A3sg+P3sg+Gen	dünya+Noun
tanınmış **tanı**+Verb^DB+**Verb**+Pass+Pos+Narr+A3sg	tanı+Verb
isimleri **isim**+**Noun**+A3pl+P3sg+Nom	isim+Noun
yeni **yeni**+**Adj**	yeni+Adj
yılı **yıl**+**Noun**+A3sg+Pnon+Acc	yıl+Noun
çalışarak **çalış**+Verb+Pos^DB+**Adverb**+ByDoingSo	çalış+Adverb
karşıladı **karşıla**+**Verb**+Pos+Past+A3sg	karşıla+Verb

4.3.5. İDM Tip - V – Kök + Son Çekim Grubu

Tip-V İDM, çözümlemede yer alan sözcük kökü ile son ÇG ile oluşturulur. Bu anlamda tip-I ile tip-III İDM birleşimi olarak yorumlanabilir.

Tablo 4-6 : Tip-V İDM için örnek eğitim tümcesi

Sözcük Biçimbirimsel Çözümlemesi	**İDM Eğitim Verisi**
Müzik **müzik+Noun+A3sg+Pnon+Nom**	müzik+Noun+A3sg+Pnon+Nom
dünyasının **dünya+Noun+A3sg+P3sg+Gen**	dünya+Noun+A3sg+P3sg+Gen
tanınmış **tanı**+Verb^DB+**Verb+Pass+Pos+Narr+A3sg**	tanı+Verb+Pass+Pos+Narr+A3sg
isimleri **isim+Noun+A3pl+P3sg+Nom**	isim+Noun+A3pl+P3sg+Nom
yeni **yeni+Adj**	yeni+Adj
yılı **yıl+Noun+A3sg+Pnon+Acc**	yıl+Noun+A3sg+P3sg+Nom
çalışarak **çalış**+Verb+Pos^DB+**Adverb+ByDoingSo**	çalış+Adverb+ByDoingSo
karşıladı **karşıla+Verb+Pos+Past+A3sg**	karşıla+Verb+Pos+Past+A3sg

4.3.6. İDM Tip -VI – Tüm Etiketler

Son İDM tipi ise tüm biçimbirimsel özellikleri kapsayan model olarak belirlenmiştir:

Tablo 4-7 : Tip - VI İDM için örnek eğitim tümcesi

Sözcük Biçimbirimsel Çözümlemesi	**İDM Eğitim Verisi**
Müzik	Noun+A3sg+Pnon+Nom

müzik+**Noun+A3sg+Pnon+Nom**	
dünyasının dünya+**Noun+A3sg+P3sg+Gen**	Noun+A3sg+P3sg+Gen
tanınmış tanı+**Verb^DB+Verb+Pass+Pos+Narr+A3sg**	Verb^DB+Verb+Pass+Pos+Narr+A3sg
isimleri isim+**Noun+A3pl+P3sg+Nom**	Noun+A3pl+P3sg+Nom
yeni yeni+**Adj**	Adj
yılı yıl+**Noun+A3sg+Pnon+Acc**	Noun+A3sg+P3sg+Nom
çalışarak çalış+**Verb+Pos^DB+Adverb+ByDoingSo**	Verb+Pos^DB+Adverb+ByDoingSo
karşıladı karşıla+**Verb+Pos+Past+A3sg**	Verb+Pos+Past+A3sg

Sözcüklerin biçimbirimsel çözümlemelerinde yer alan, kök hariç diğer tüm etiketlerden oluşan İDM Tip-VI, biçimbirimsel yapıların en geniş kapsamlı modellendiği İDM tipidir.

4.3.7. Farklı Dil Modeli Tiplerinin Entropi Değerleri

Geliştirilen dil modeli tiplerinin değerlendirilmesi amacı ile yaklaşık 5000 sözcükten oluşan ve ilgili tipin modellediği bilgileri (kök, son sözcük türü gibi) içeren sınama kümeleri hazırlanmıştır. Bu sınama kümesi üzerinde hesaplanan entropi değerleri Tablo 4-8'de verilmiştir.

Bu tablo inclendiğinde, genel olarak $n \geq 3$ için entropi değerinin azalmadığı (hatta bazı durumlarda arttığı) görülmektedir. Bu ise 3. dereceden İDM kullanmanın yeterli olacağı, 4. ve 5. dereceden İDM'leri kullanmanın getirdiği yeni bir bilgi olmadığı sonucunu doğurmaktadır. Bu noktada, sınama verisinin, dilin tamamını temsil ettiği varsayılmıştır.

Tablo 4-8 : Farklı tipte ve derecede İDM'lerin entropi değerleri

İDM Tipi	**Entropi (bit)**				
	n=1	**n=2**	**n=3**	**n=4**	**n=5**
Tip-I – Kök	10,32	8,93	8,79	8,79	8,80
Tip-II – Son Sözcük Türü	2,43	2,30	2,27	2,26	2,26
Tip-III – Son Çekim Grubu	6,27	5,77	5,69	5,69	5,69
Tip-IV – Kök + Son Sözcük Türü	10,88	9,50	9,38	9,39	9,39

Tip-V – Kök + Son Çekim Grubu	12,72	11,48	11,41	11,41	11,41
Tip-VI – Tüm Çözümleme (kök hariç)	6,64	6,15	6,08	6,08	6,08

5. TÜRK DİL AİLESİ

Türk dil ailesi, çoğunlukla Orta Asya coğrafyasına yayılmış ve toplamda yaklaşık 180 milyon insanın kullandığı, aynı temelleri paylaşan ve birçok benzer özelliği bulunan dillerden oluşmaktadır. Türkiye Türkçe'si ile diğer Türk dilleri arasında benzerliğin yüksek olması, bağlantılı diller olan Türk dillerinde sözcük köklerinin çoğunlukla aynı kalmasından kaynaklanmaktadır [48].

Türk dil ailesindeki Türk dillerinin lehçe mi yoksa ayrı birer dil mi olduğu dil bilimciler arasında halen bir tartışma konusudur. Bu konuda bizim kabul ettiğimiz görüş, karşılıklı anlaşılabilirlik (mutual intelligibility) ilkesine dayanan ve Türk dillerini ayrı birer dil olarak niteleyen görüştür [49]. Türk dil ailesinin sınıflandırılması şu şekildedir [50]:

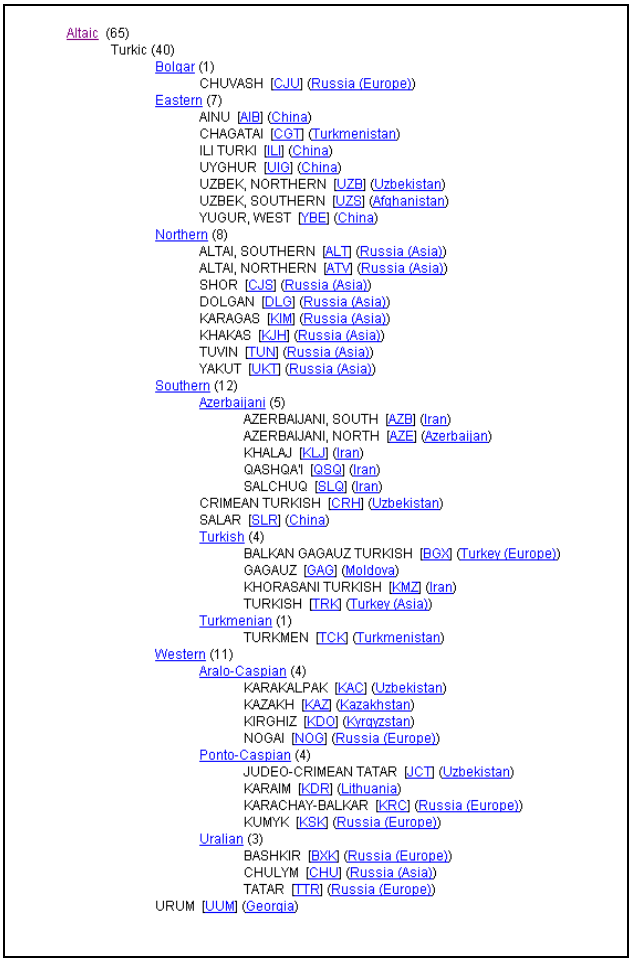

Şekil 5-1 : Türk Dil Ailesinin Sınıflandırması

Şekil 5-2 : Türk Dillerinin konuşulduğu başlıca coğrafyaların haritası

Türk dilleri çoğunlukla eski SSCB'den ayrılarak bağımsızlığını ilan eden ülkelerde konuşulmaktadır. Türk dillerinin konuşulduğu başlıca ülkelere ilişkin coğrafi bölgenin haritası Şekil 5-2'de verilmiştir.

Tablo 5-1 : Türk Dilleri ile ilgili bazı bilgiler

Dil	Dil Kodu	Kullanıldığı Bölge (Başlıca)	Kullanan Kişi Sayısı (Yaklaşık)
Türkçe	TRK	Türkiye	72 milyon
Azerice	AZB	İran	24,3 milyon
Azerice	AZE	Azerbaycan	7 milyon
Türkmence	TCK	Türkmenistan	6,4 milyon
Kazakça	KAZ	Kazakistan	8 milyon
Kırgızca	KDO	Kırgızistan	2,6 milyon
Uygurca	UIG	Çin (Doğu Türkistan bölgesi)	7,6 milyon
Özbekçe	UZB	Özbekistan	18,5 milyon
Özbekçe	UZS	Afganistan	1.4 milyon
Çuvaşça	CJU	Rusya	2 milyon

Günümüz Türkiye Türkçesine en çok benzeyen diller, aynı sınıf içerisinde yer alan Azerice, Türkmence ve Gagauz (Gök Oğuz) Türkçesidir. Özbekçe'nin, Türkçe konuşanlar tarafından anlaşılabilirlik derecesi ortadır. Özbekçe'yi bilenler, Türkmen, Uygur, Kazakça ve Kırgızca'yı daha rahat anlar ve konuşurlar. Kırgızca ve Kazakça, coğrafi olarak Türkiye'ye uzak oldukları için Türkçe'ye Özbekçe ve Türkmence'den daha uzaktır. Kıpçak grubundaki diller arasında Türkçe'ye en yakın dil Kırım-Tatar Türkçesi'dir. Yakutça ve Çuvaşça'yı ise Türkçe'yi konuşanların anlaması artık mümkün değildir [48].

5.1. Türk Dilleri Arasındaki Benzerlikler

Türk dilleri anlam ve biçim açısından incelendiğinde birçok benzerlik ve aynılık olduğu görülür. Benzerlikler, sözcük dağarcıklarındaki ortak sözcükler açısından incelendiğinde baskın olarak adıllar, sıfatlar, ilgeçler, belirteçler, zamanla ilgili sözcükler, organ isimleri, doğa, bitki ve hayvan isimlerinde ortak kullanımların olduğu görülmektedir. Ayrıca sözdizimsel açıdan bütün Türk dilleri özne-nesne-yüklem (SOV) sırasını kullanmaktadır. Ortak sözcüklerin dışında Türk dillerinin benzerlikleri, biçimbirimsel açıdan incelendiğinde ise ek türlerinin ve ekleniş biçimlerinin çoğu kez aynı olduğu görülmektedir. Örneğin Tablo 5-2'de bazı Türk dilleri için isim durum ekleri verilmiştir [48]. Hemen hemen bütün Türk dillerinde özellikle adlara eklenen çekim eklerinin türleri ve sıraları aynıdır. Büyük ünlü uyumu, küçük ünlü uyumu, ünsüz benzeşmesi gibi bazı yazım kuralları da hepsinde görülmese de bazı Türk dillerinde ortak olarak bulunur. Tüm bu benzerliklere örnek olarak aşağıda farklı Türk dillerinde ortak olarak kullanılan iki deyim verilmiştir.

```
Turkish     : Ağır  kazan geç  kaynar.
Azerbaijani : Ağır  qazan geç  qaynayar.
Turkmen     : Agyr  gazan giç  gaýnar.
Uzbek       : Çuqur därya tinç aqar.
Kirghiz     : Oor   kazan keç  kaynayt.
Kazakh      : Awur  qazan keş  qaynaydı.

Turkish     : Dağ dağa       kavuşmaz,  insan insana     kavuşur.
Azerbaijani : Dağ dağa       govuşmaz,  insan insana     govuşur.
Turkmen     : Dag daga       duşmaz,    adama adama      duşar.
Uzbek       : Tåğ tåğ bilän  qavuşmas,  adam  adam bilän qavuşar.
Kirghiz     : Too tooğo      koşulbayt, adam  menen adam koşulat.
Kazakh      : Taw tawğa      qosılmas,  adam  adamğa     qosıldı.
```

Görüldüğü gibi sözcük sıraları çoğunlukla aynıdır. Yalnızca bazı sözcükler bazı Türk dillerinde iki ya da daha fazla sözcükle ifade edilmektedir.

Tablo 5-2 : Bazı Türk Dilleri için isim durum ekleri

Ad Durum Ekleri	Türkçe	Azerice	Türkmence	Özbekçe	Kırgızca	Kazakça	Uygurca
Belirtme Durumu	+ı (+i,+u,+ü) +yı (+yi,+yu,+yü)	+ı (+i,+u,+ü) +nı (+ni,+nu,+nü)	+y (+i) +ny (+ni)	+ni	+nı (+ni,+nu,+nü) +dı (+di,+du,+dü) +tı (+ti,+tu,+tü) +n	+nı (+ni) +dı (+di) +tı (+ti) +n	+ni
Yönelme Durumu	+a (+e) +ya (+ye)	+a (+ə) +ya (+yə)	+a (+e, +ä)	+gä +kä +qa	+ga (+ge,+go,+gö) +ka (+ke,+ko,+kö) +na (+ne,+no,+nö) +a (+e, +o,+ö)	+ğa (+ge) +qa (+ke) +a (+e)	+ga (+ge) +ka (+ke)
Kalma Durumu	+da (+de) +ta (+te)	+da (+də)	+da (+de)	+dä	+da (+de,+do,+dö) +ta (+te,+to,+tö)	+da (+de) +ta (+te) +nda (+nde)	+da (+de) +ta (+te) +nda (+nde)
Çıkma Durumu	+dan (+den) +tan (+ten)	+dan (+dən)	+dan (+den)	+dän	+dan(+den,+don,+dön) +tan (+ten,+ton,+tön) +nan(+nen,+non,+nön)	+dan (+den) +tan (+ten) +nan (+nen)	+din +tin
Tamlayan Durumu	+ın (+in,+un,+ün) +nın (+nin,+nun,+nün)	+ın (+in,+un,+ün) +nın (+nin,+nun,+nün)	+yñ (+iñ,+uñ,+üñ) +nyñ (+niñ)	+niñ	+nın (+nin,+nun,+nün) +dın (+din,+dun,+dün) +tın (+tin,+tun,+tün)	+nıñ (+niñ) +dıñ (+diñ) +tıñ (+tiñ)	+niñ

5.2.

5.3. Türk Dilleri Arasındaki Farklılıklar

Tümceler arasında sözcük sıraları açısından çoğunlukla benzerlik söz konusu olsa da bazı durumlarda tümce içindeki sözcüklerin yerleri de değişebilir. Örnek olarak çoğu Türk dilinde bulunan aşağıdaki atasözü verilmiştir:

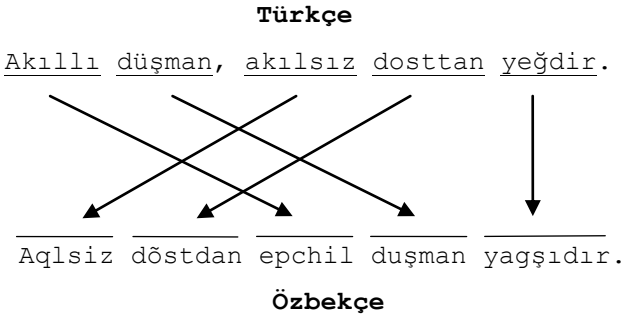

Şekil 5-3 : Türkçe-Özbekçe tümcelerde sözcük sıraları farklılığı örneği

Ancak Türk dillerinde, sözcük öbeklerinin tümce içerisinde yer değiştirebilmesi özelliği bulunduğundan, Özbekçe tümce Türkçe'ye çevrilirken sözcük sıralarında bir değişikliğe gidilmese bile anlamı koruyan Türkçe tümce üretilebilir:

```
Akılsız dosttan akıllı düşman yeğdir.
```

Yazım dili açısından Türk dilleri tarihte farklı abece sistemlerini kullanmışlardır. Özellikle SSCB'nin zorlaması ile bir bu bölgelerde kullanılan Türk dilleri Kiril abecesi ile yazılmaya başlanmıştır. Bunların dışında Arap ve Latin abecesini kullanan diller birbirlerine yakınlaşırken, bu süreçte Kril abecesini kullanan diller bilinçli olarak farklılaştırılmıştır. Günümüzde Çinde konuşulan ve Arap abecesini kullanan Uygurca dışındaki bütün Türk dilleri Latin abecesine geçiş yapmışlardır.

Türk dilleri arasında gözlenebilen diğer farklılıklar özellikle eylem çekimlerinde ortaya çıkan farklı zaman kullanımları, dillere özel kipler ve özne-yüklem uyumlarındaki farklılıklardır. Örneğin Türkçe'deki geniş zaman kalıbı Türkmence'de gelecek zaman anlamını taşır. Ayrıca Türkmence'de, Türkçe'de bulunmayan ***+makçı/+mekçi*** ekleri ile kurulan ve "bir eylemi yapmayı düşünmek/yapmaya niyetlenmek" anlamında bir eylem kipi bulunur.

5.4. Türk Dilleri Hakkında Özet Bilgiler

Bu bölümde başlıca Türk dillerinin temel özellikleri ve abeceleri ile ilgili bilgiler verilecektir. Abecelerin gösterildiği tablolarda, koyu ve eğik olarak belirtilen harfler, Türkçe'de olmayan ya da farklı sesler için kullanılan harfleri göstermektedir.

5.4.1. Azerice

Azeri Türkçe'sinin yeni abecesinde 32 harf vardır. Türkçe'den farklı olan bu üç harf (ə, x ve q) Tablo 5-3'de kalın olarak gösterilmiştir.

Tablo 5-3 : Azerice'nin abecesi

	Azeri Abecesi		**Türkçe Karşılığı**
1	A	A	a
2	B	B	b
3	C	C	c
4	Ç	Ç	ç
5	D	D	d
6	E	E	e
7	***Ə***	***ə***	***ince e***
8	F	F	f
9	G	G	g
10	Ğ	Ğ	ğ
11	H	H	he
12	***X***	***x***	***ha***
13	I	I	ı
14	I	İ	i
15	J	J	j
16	K	K	ke
17	***Q***	***q***	***ka***
18	L	L	l
19	M	M	m
20	N	N	n
21	O	O	o
22	Ö	Ö	ö
23	P	P	p
24	R	R	r
25	S	S	s
26	Ş	Ş	ş
27	T	T	t
28	U	U	u
29	Ü	Ü	ü
30	V	V	v
31	Y	Y	y
32	Z	Z	z

Azericede, Türkçe'deki gibi büyük ve küçük ünlü uyumu bulunur. Buna karşın Türkçe'deki ünsüz benzeşmesi ise gözlenmez.

Azerice isim çekimi, Türkçe'ye çok benzemektedir ancak arada küçük farklılıklar da vardır.

Tekillik / Çoğulluk

Çoğulluk ekleri ***+lar*** ve ***+lər*** Türkçe'deki ile aynı şekilde kullanılır.

Belirtme Durumu

Örneğin belirtme durumu eki Türkçe'deki gibi ***+ı, +i, +u*** ve ***+ü*** eklerinden oluşmaktadır. Ancak Azerice'de ekten önce sesli harf bulunursa araya ***y*** harfi yerine ***n*** harfi gelir:

```
dəpdəri (defteri)       xalgı (halkı)          kulağımızı (qulağımızı)
arabanı (arabayı)       sürücünü (sürücüyü)    ölçünü (ölçüyü)
```

Yönelme Durumu

Türkçe'deki gibi ***+a*** ve ***+ə*** ekleri ile kurulur.

```
dəpdərə (deftere)   xalga (halka)       anaya (anaya)
```

Kalma Durumu

Türkçe'dekine benzer olarak ***+da, +də*** ekleri ile kurulur. Türkçe'deki kullanımdan tek farklı bu eklerin ünsüz benzeşmesine uymamasıdır (***+ta, +te*** halleri yoktur):

```
başda (başta)        evdə (evde)          kitapda (kitapta)
```

Çıkma Durumu

Çıkma durumu, ***+dan*** ve ***+dən*** ekleri ile kurulur. Bu ekler de ünsüz benzeşmesine uymazlar:

```
atdan (attan)        evdən (evden)        kitapdan (kitaptan)
```

Tamlayan Durumu

Tamlayan durumu ekleri de Türkçe ile tamamen aynıdır:

```
kitabın (kitabın)    xalgın (halkın)      ölünün (ölünün)
```

5.4.2. Türkmence

1920'lere kadar Latin abecesini kullanırken, Rusya'nın egemenliği altına girdikten sonra Kiril abecesini kullanmaya başlanmıştır. 1990'lardan sonra bağımsızlığını elde eden Türkmenistan'ın Kiril abecesinden, Latin abecesine dönüşü sancılı olmuştur. Standart bir abece ortaya çıkana kadar çok farklı Latin harfleri kullanılmıştır. Ancak Türkmenistan Milli Meclisi, 12.04.1993 tarihinde "Yeni Türkmen Abecesi"ni kabul ederek, abece konusundaki kargaşalara son vermiştir [48]. Günümüzde kullanımda olan Türkmen abecesi Tablo 5-4'de verilmiştir. Türkmence'nin biçimbirimsel yapısı Bölüm 7.1.1'de ayrıntılı olarak ele alınacağından burada anlatılmamıştır.

Tablo 5-4 : Türkmence'nin abecesi

	Türkmen Abecesi		Türkçe Karşılığı
1	A	a	A
2	B	b	B
3	***J***	***j***	***c***
4	Ç	ç	ç
5	D	d	d
6	E	e	e
7	***Ä***	***ä***	***ince e***
8	F	f	f
9	G	g	g
10	H	h	h
11	***Y***	***y***	***ı***
12	I	i	i
13	***Ź***	***ź***	***j***
14	K	k	k
15	L	l	l
16	M	m	m
17	N	n	n
18	***Ñ***	***ñ***	***ince (nazal) n***
19	O	o	o
20	Ö	ö	ö
21	P	p	p
22	R	r	r
23	S	s	s
24	Ş	ş	ş
25	T	t	t
26	U	u	u
27	Ü	ü	ü
28	***W***	***w***	***v***
29	***Ý***	***ý***	***y***
30	Z	z	z

5.4.3. Kazakça

Kazakça, Doğu Türkistan'da, Moğolistan'da, Rusya'da ve Orta Asya'nın bazı bölümlerinde konuşulur; Abecesinde toplam 32 harf bulunur:

Tablo 5-5 : Kazakça'nın abecesi

	Kazak Abecesi		Türkçe Karşılığı
1	A	A	a
2	B	B	b
3	J	J	c
4	D	D	d
5	E	E	e
6	***Ä***	***Ä***	***ince e***
7	F	F	f
8	G	G	g
9	Ğ	Ğ	ğ
10	H	H	he
11	***X***	***X***	***ha***
12	I	I	ı
13	İ	İ	i
14	K	K	ke
15	***Q***	***Q***	***ka***
16	L	L	l
17	M	M	m
18	N	N	n
19	***Ñ***	***Ñ***	***ince (nazal) n***
20	O	O	o
21	Ö	Ö	ö
22	P	P	p
23	R	R	r
24	S	S	s
25	Ş	Ş	ş
26	T	T	t
27	U	U	u
28	Ü	Ü	ü
29	V	V	v
30	Y	Y	y
31	Z	Z	Z
32	***W***	***W***	***v***

Kazak Türkçesi'nde büyük ünlü uyumu kuralı gözlenmektedir. Küçük ünlü uyumu da kural olarak bulunmasına karşın bazı sözcükler küçük ünlü uyumuna uymaz. Kazak Türkçe'sinde ünsüz benzeşmesi kuralı da bulunur:

kitaptı (kitaptı) qısta (kışta) şaşta (saçta)

Kazakça'nın isim çekim ekleri Türkçe'ninkinden biraz farklıdır.

Tekillik / Çoğulluk

- Ünlüler ve ***r, w, y*** ünsüzlerinden sonra ***+lar*** ve ***+ler*** eki gelir:

```
balalar (çocukar)    qoylar (koyunlar)       tawlar (dağlar)
```

- Yumuşak ünsüzlerden sonra ***+dar*** ve ***+der*** eki gelir:

```
qazdar (kazlar)      qoyındar (koyunlar)     öleñder (ölenler)
```

- Sert ünsüzlerden sonra ***+tar*** ve ***+ter*** eki gelir:

```
ağaştar (ağaçlar)    esikter (kapılar)       tister (dişler)
```

Belirtme Durumu

- Ünlülerden sonra ***+nı, +ni*** eki gelir:

```
almanı (elmayı)      evi (üyini)             atanı (atayı)
```

- Yumuşak ünsüzlerden sonra ***+dı, +di*** eki gelir:

```
qalamdı (kalemi)     küldi (gülü)            qarındı (karnı)
```

- Sert ünsüzlerden sonra ***+tı, +ti*** eki gelir:

```
uşaqtı (uçağı)       esikti (kapıyı)         balıqtı (balığı)
```

Yönelme Durumu

- Ünlülerden ve yumuşak ünsüzlerden sonra ***+ğa, +ge*** eki gelir:

```
köşege (caddeye)     üyge(eve)               olarğa(onlara)
```

- Sert ünsüzlerden sonra ***+qa, +ke*** eki gelir:

```
qonaqqa (konuğa)     iske(işe)               aşqa(aşa)
```

- Tekil 1. ve 2. kişi iyelik ekinden sonra ***+a, +e*** gelir:

```
qalama (şehrime)     dosına(dostuna)         üyine(evine)
```

- Tekil ve çoğul 2. iyelik eklerinden sonra ***+na, +ne*** gelir:

```
awlına(köyüne)       qolına(eline)           köline(gölüne)
```

Kalma Durumu

- Ünlülerden ve yumuşak ünsüzlerden sonra ***+da, +de*** eki gelir:

```
qazda (kazda)        qumda (kumda)           elde(ülkede)
```

- Sert ünsüzlerden sonra ***+ta, +te*** eki gelir:

```
ata(atta)            tiste (dişte)           köşte(göçte)
```

Çıkma Durumu

- Ünlülerden ve yumuşak ünsüzlerden sonra ***+dan, +den*** eki gelir:

joldan(yoldan) üyden(evden) sizden(sizden)

- Sert ünsüzlerden sonra ***+tan, +ten*** eki gelir:

qıştan(kıştan) küşten(güçten) ayaqtan(ayaktan)

- ***m, n, ñ*** ve 3. iyelik eklerinden sonra ***+nan, +nen*** eki gelir:

adamnan(adamdan) üyine(evinden) innen(inden)

Tamlayan Durumu

- Ünlülerden ve m, n, ñ ünsüzlerinden sonra ***+nıñ, +niñ*** eki gelir:

balanıñ(çocuğun) şeşeniñ(annenin) künniñ(güneşin)

- Yumuşak ünsüzlerden sonra ***+dıñ, +diñ*** eki gelir:

olardıñ(onların) joldıñ(yolun) köldiñ(gölün)

- Sert ünsüzlerden sonra ***+tıñ, +tiñ*** eki gelir:

qustıñ(kuşun) jürektiñ(yüreğin) küştiñ(gücün)

5.4.4. Kırgızca

Kırgız abecesinde toplam 30 harf vardır. Kırgızcanın yeni abecesi Tablo 5-6'da verilmiştir:

Tablo 5-6 : Kırgızca'nın abecesi

	Kırgız Abecesi		Türkçe Karşılığı
1	A	A	a
2	B	B	b
3	C	C	c
4	Ç	Ç	ç
5	D	D	d
6	***E***	***E***	***ince e***
7	***É***	***É***	***e***
8	F	F	f
9	G	G	g
10	Ğ	Ğ	ğ
11	H	H	h
13	I	I	ı
14	I	İ	i
16	K	K	k
18	L	L	l
19	M	M	m
20	N	N	n
21	***Ñ***	***Ñ***	***ince (nazal) n***
22	O	O	o
23	Ö	Ö	ö
24	P	P	p
25	R	R	r
26	S	S	s
27	Ş	Ş	ş
28	T	T	t
29	U	U	u
30	Ü	Ü	ü
31	V	V	v
31	Y	Y	y
32	Z	Z	z

Türk dil ailesindeki dillerde genellikle iki ünlü yan yana gelmezken Kırgızca'da bu durum çok sık görülür. Bu durum, ünlünün uzun okunması gerektiği gösterir. Aslında diğer Türk dillerinde de okunuşu uzun olan ünlülerin bulunmaktadır. Ancak bu dillerde, yazı dilinde bu durum belirtilmemesine rağmen Kırgızca'da ünlü harfin iki defa yazılması ile belirtilir.

Kırgızcada büyük ünlü uyumu vardır. Ayrıca Türkçe'dekine çok benzer küçük ünlü uyumu da bulunur. Ünsüz benzeşmesi de Kırgızca'nın Türkçe'ye benzeyen özelliklerindendir.

Tekillik / Çoğulluk

- Ünlülerden sonra ***+lar***, ***+ler, +lor*** ve ***+lör*** ekleri gekir:

```
talaalar (bozkırlar) köçölör (köşeler)      ündüülör (ünlüler)
```

- Yumuşak ünsüzlerden sonra ***+dar***, ***+der, +dor*** ve ***+dör*** ekleri gelir:

```
kağazdar (kağıtlar)  közdör (gözler)        kalemder(kalemler)
```

- Sert ünsüzlerden sonra ***+tar***, ***+ter, +tor*** ve ***+tör*** ekleri gelir:

```
tooktor (tavuklar)   baştar (başlar)        cigitter (yiğitler)
```

Belirtme Durumu

- Ünlülerden sonra ***+nı, +ni, +nu*** ve ***+nü*** ekleri gelir:

```
baanı (kıymetini)    toonu (dağı)           cazuunu (yazıyı)
```

- Yumuşak ünsüzlerden sonra ***+dı, +di, +du*** ve ***+dü*** ekleri gelir:

```
kagazdı (kağıdı)     üydü (evi)             kazdı (kazı)
```

- Sert ünsüzlerden sonra ***+tı, +ti, +tu*** ve ***+tü*** ekleri gelir:

```
kuştu (kuşu)         küçtü (güçü)           attı (atı)
```

Yönelme Durumu

- Ünlülerden ve yumuşak ünsüzlerden sonra ***+ga, +ge, +go*** ve ***+gö*** ekleri gelir:

```
toogo (dağa)         küzgö (güze)           elge (halka)
```

- Sert ünsüzlerden sonra ***+ka, +ke, +ko*** ve ***+kö*** ekleri gelir:

```
mektepke(okula)      taşka (taşa)           tüpko (dibe)
```

- Tekil 1. ve 2. kişi iyelik ekinden sonra ***+a, +e, +o*** ve ***+ö*** gelir:

```
balama (çocuğuöa)    elime (halkıma)        közümö (gözüme)
```

- Tekil 3. kişi iyelik eklerinden sonra ***+na, +ne, +no*** ve ***+nö*** gelir:

```
atasına (atasına)    toosuna (dağına)       ağasına(ağabeyine)
```

Kalma Durumu

- Ünlülerden ve yumuşak ünsüzlerden sonra ***+da, +de, +do*** ve ***+dö*** eki gelir:

```
caanda (yağmurda)    köldö(gölde)           coldo(yolda)
```

- Sert ünsüzlerden sonra ***+ta, +te, +to*** ve ***+tö*** eki gelir:

```
kitepte(kitapta)     atta(atta)              tookto(tavukta)
```

Çıkma Durumu

- Ünlülerden ve yumuşak ünsüzlerden sonra ***+dan, +den, +don*** ve ***+dön*** eki gelir:

```
toodon(dağdan)       közdön(gözden)          oozdon(ağızdan)
```

- Sert ünsüzlerden sonra ***+tan, +ten, +ton*** ve ***+tön*** eki gelir:

```
kitepten(kitaptan)   tüptön(dipten)          tookton(tavuktan)
```

- 3. tekil iyelik eklerinden sonra ***+nan, +nen, +non*** ve ***+nön*** eki gelir:

```
colunan(yolundan)    apasınan(anasından)     közünön(gözünden)
```

Tamlayan Durumu

- Ünlülerden ünsüzlerinden sonra ***+nın, +nin, +nun*** ve ***+nün*** eki gelir:

```
kalaanın(şehrin)     talaanın(annenin)       toonun(dağın)
```

- Yumuşak ünsüzlerden sonra ***+dın, +din, +dun*** ve ***+dün*** eki gelir:

```
ağamdın(ağabeyimin)  bizdin (bizim)          közümdün(gözümün)
```

- Sert ünsüzlerden sonra ***+tın, +tin***, ***+tun*** ve ***+tün*** eki gelir:

```
curttun(yurdun)      kiteptin (kitabın)      çaçtın(saçın)
```

- ***+ki*** ekinden önce gelen ***n*** ünsüzü düşer:

```
eceniki(ablanınki)   üydükü(evinki)          sizdiki(sizinki)
```

5.4.5. Uygurca

Uygurca, Doğu Türkistan'da ve Orta Asya'nın değişik bölgelerinde kullanılır. Doğu Türkistan'daki Uygular Arap abecesini kullanırken diğerleri Kiril abecesini kullanmaktadır. Tablo 5-7'de Uygur abecesindeki Arap harflerinin Latin harfleriyle yazılmış bir sürümü verilmiştir.

Tablo 5-7 : Uygurca'nın abecesi

	Uygur Abecesi		Türkçe Karşılığı
1	A	A	A
2	B	B	B
3	C	C	c
4	Ç	Ç	ç
5	D	D	d
6	***É***	***É***	***e***
7	***E***	***E***	***ince e***
8	F	F	f
9	G	G	g
10	Ğ	Ğ	ğ
11	H	H	he
12	***Ḥ***	***ḥ***	***ha***
14	I	İ	i
15	J	J	j
16	K	K	ke
17	***Ḳ***	***ḳ***	***ka***
18	L	L	l
19	M	M	m
20	N	N	n
21	***Ñ***	***ñ***	***ince (nazal) n***
22	O	O	o
23	Ö	Ö	ö
24	P	P	p
25	R	R	r
26	S	S	s
27	Ş	Ş	ş
28	T	T	t
29	U	U	u
30	Ü	Ü	ü
31	V	V	v
32	Y	Y	y
33	Z	Z	z

Uygurca'da büyük ünlü uyumu kısmen gözlense de küçük ünlü uyumu gözlenmez.

Tekillik / Çoğulluk

Uygurca'nın çoğul ekleri Türkçe'deki ***+lar*** ve ***+ler*** ekleridir.

Belirtme Durumu

Belirtme durumu eki büyük ünlü uyumuna uymayan ***+ni*** ekidir.

```
adämni (adamı)       işlerni (işlrei)    kitapni (kitabı)
```

Yönelme Durumu

Yönelme durumu eki ***+ga*** ve ***+ge*** ekleridir. Ünsüz benzeşmesine uyan bu ek sert ünsüzlerden sonra ***+ka*** ve ***+ke*** biçiminde kullanılır.

```
adämge (adama)       işlerge (işlere)    etrafka (etrafka)
```

Kalma Durumu

Belirtme durumu eki ***+da*** ve ***+de***'dir. Ünsüz benzeşmesine uyarak bu ek sert ünsüzlerden sonra ***+ta*** ve ***+te*** biçimlerine dönüşür.

```
kutuda (kutuda)       işte (işte)         közlerimizde (gözlerimizde)
```

Çıkma Durumu

Uygurca'daki çıkma durumu eki ***+din***'dir. Bu ek ilginç bir davranış göstererek ünlü uyumuna uymaz ama ünsüz benzeşmesine uymaktadır.

```
sizdin (sizden)      yoldin (yoldan)     çeçäktin (çiçekten)
```

Tamlayan Durumu

Belirtme durumu eki ***+niñ***'dir.

```
Ankara'niñ (Ankara'nın)  işniñ (işin)    adämniñ (adamın)
```

5.4.6. Özbekçe

Özbek dilinde konuşma dilinde gözlenen büyük ünlü uyumu kuralına yazı dilinde rastlanmaz. Bunun nedeni, konuşma dilinde mevcut olan ***ı, ö*** ve ***ü*** seslerine karşılık yazı dilinde bir harf kullanılmamasıdır.

Tablo 5-8 : Özbekçe'nin abecesi

	Özbek Abecesi		Türkçe Karşılığı
1	***O (Å)***	***o (å)***	***a***
2	B	B	b
3	***J***	***J***	***c***
4	Ç	Ç	ç
5	D	D	d
6	E	E	e
7	***Ä***	***Ä***	***ince e***
8	F	F	f
9	G	G	g
10	Ğ	Ğ	ğ
11	H	H	he
12	***X***	***X***	***ha***
13	***I***	***İ***	***ı,i***
14	J	J	j
15	K	K	ke
16	***Q***	***Q***	***ka***
17	L	L	l
18	M	M	m
19	N	N	n
20	***Ñ***	***Ñ***	***ince (nazal) n***
21	***Ō***	***Ō***	***o, ö***
22	P	P	p
23	R	R	r
24	S	S	s
25	Ş	Ş	ş
26	T	T	t
27	***U***	***U***	***u, ü***
28	V	V	v
29	Y	Y	y
30	Z	Z	z

Özbekçe'de büyük ve küçük ünlü uyumu ile birlikte ünsüz benzeşmesi kuralı da yoktur.

Tekillik / Çoğulluk

Büyük ünlü uyumu kuralı olmadığı için Özbekçe'de çoğul eki tektir : ***+lär***

Belirtme Durumu

Belirtme durumu eki yalnızca ***+ni***'dir.

```
uyni (evi)          yōlni (yolu)        kitåbni (kitabı)
```

Yönelme Durumu

Yönelme durumu eki ***+ga***'dır. Ancak ***-k*** harfi ile biten sözcüklerde +***kä, -q*** ve ***-ğ*** harfi ile biten sözcüklerde ise ***+qa*** olarak kullanılır.

```
uygä (eve)          kōrekkä (küreğe)    baqqa (bağa)
```

Kalma Durumu

Kalma durumu eki yalnızca ***+dä***'dir.

```
uydä (evde)         bizdä (bizde)       kitåbdä (kitapta)
```

Çıkma Durumu

Çıkma durumu eki yalnızca ***+dän***'dir.

```
uydän (evden)       bizdän (bizden)     kitåbdän (kitaptan)
```

Tamlayan Durumu

Tamlayan durumu eki yalnızca ***+nin***'dir.

```
uyniñ (evin)          bizniñ (bizim)    kitåbniñ (kitabın)
```

6. TÜRK DİLLERİ ARASINDA BİLGİSAYARLI ÇEVİRİ

Bu kısma 6.1 gibi Giriş adı vermek doğru olmaz o yüzden kaldırdım

Türk dilleri arasında çeviri yaparken ortaya çıkan en büyük sorun, Türkçe dışındaki haricindeki diğer Türk dilleri için doğal dil işleme çalışmalarının yok denecek kadar az olmasıdır. Bir çok Türk dili için biçimbirimsel çözümleme, sözdizim çözümleme gibi araçlar ya da elektronik ortama aktarılmış sözlükler veya işlenmiş metinler bulmak olası değildir. Türkçe için bile genel amaçlı kullanılabilecek yüksek başarımlı bir sözdizimsel çözümleme aracı bulunmamaktadır.

Bütün bu olumsuzluklara karşın, özellikle Türk dillerinin sözdiziminin benzer olması (Azerice, Türkmence gibi bazı diller için neredeyse aynı olması), Bölüm 3.1'de anlatılan aktarım yöntemleri arasında en temel yöntem olan doğrudan aktarım yönteminin bile başarılı sonuçlar üretebileceğini düşündürmektedir.

Doğrudan aktarım yöntemi hariç diğer tüm bilgi tabanlı aktarım yöntemlerinde, sözdizim çözümlemesi, anlamsal çözümleme gibi üst düzey bilgiler gerekmektedir. Ancak Türk dilleri söz konusu olduğunda bu bilgileri üretecek araçlar dahi bulunmamaktadır.

İstatistiksel ve örnek tabanlı çalışan yöntemleri kullanabilmek için ise birbirlerinin karşılığı olan hizalanmış eğitim verilerine büyük miktarlarda gerek duyulur. Bu şekilde hazırlanmış paralel eğitim verilerinin bulunmaması, ayrıca bu tür bir eğitim kümesinin hazırlanmasının yüksek maliyet gerektirmesinden dolayı bu yöntemlerin uygulanabilirliği düşüktür.

Sözcük sıralarını değiştirmeden, sadece sözcükleri birebir çevirerek gerçeklenecek doğrudan aktarım yöntemi, gerek sözdizim çözümlemesi gibi daha üst seviyede bilgilere, gerekse de istatistiksel yöntemlerin kullandığı gibi büyük miktarlarda paralel eğitim verilerine ihtiyaç duymadığı için en uygun yöntem olarak görülmektedir. Ayrıca doğrudan aktarım yöntemi, sadece sonlu durum yöntemleri kullanılarak gerçeklenebilmektedir. Bu sayede sistematik ve hızlı çalışan bir aktarım sistemi gerçeklenebilir.

Ancak Türk dilleri gibi bitişken diller söz konusu olduğunda doğrudan aktarım yöntemi Tablo 6-1'deki gibi geliştirilerek kullanılmalıdır:

Tablo 6-1 : Geliştirilmiş doğrudan aktarım yöntemi aşamaları

1. Kaynak Dil Biçimbirimsel Çözümlemesi
2. Biçimbirimsel Yapıların Hedef Dile Aktarılması
3. Sözcük Kökünün Hedef Dile Aktarılması
4. Hedef Dilde Biçimbirimsel Üretici ile Sözcüğün Yüzeysel Biçiminin Üretilmesi

Bitişken yapısından dolayı, kaynak tümcedeki bir sözcüğün karşılığını sözlükte olduğu gibi arayıp bulmak mümkün değildir. Bu noktada, bir ön işlem olarak biçimbirimsel çözümlemenin yapılması gereklidir. Biçimbirimsel çözümleme sonucunda sözcük kökü ve diğer biçimbirimsel yapılar ortaya çıkar. Artık doğrudan aktarım, kaynak dildeki bu yapıların (sözcük kökü ve biçimbirimsel yapılar) hedef dile iki aşamalı olarak aktarımı biçiminde algılanmalıdır.

Her ne kadar Türk dillerinin sözdizimsel ve biçimbirimsel yapıları birbirlerine yakın olsa da, bu diller arasında biçimbirimsel farklılıklar da azımsanmayacak boyuttadır. Biçimbirimsel farklılıkları gidermek üzere bir takım biçimbirimsel dönüşüm kuralları gerçeklenmeli ve bu kuralların işletilmesi sonucunda kaynak dildeki biçimbirimsel yapılar, hedef dil için geçerli biçimbirimsel yapılar haline gelmelidir.

İkinci aşama olarak, kaynak dilde çözümlenen sözcük kökünün karşılığı aktarım sözlüğünden bulunmalı ve hedef dildeki karşılığı veya karşılıkları ile değiştirilmelidir.

Son adımda ise elde edilen biçimbirimsel yapı, hedef dilin biçimbirimsel üreticisi tarafından yüzeysel biçime çevrilir.

Anlatılan geliştirilmiş doğrudan aktarım yöntemine göre Türkmence bir sözcüğün Türkçe karşılığının oluşturulma süreci Şekil 6-1'de gösterilmiştir.

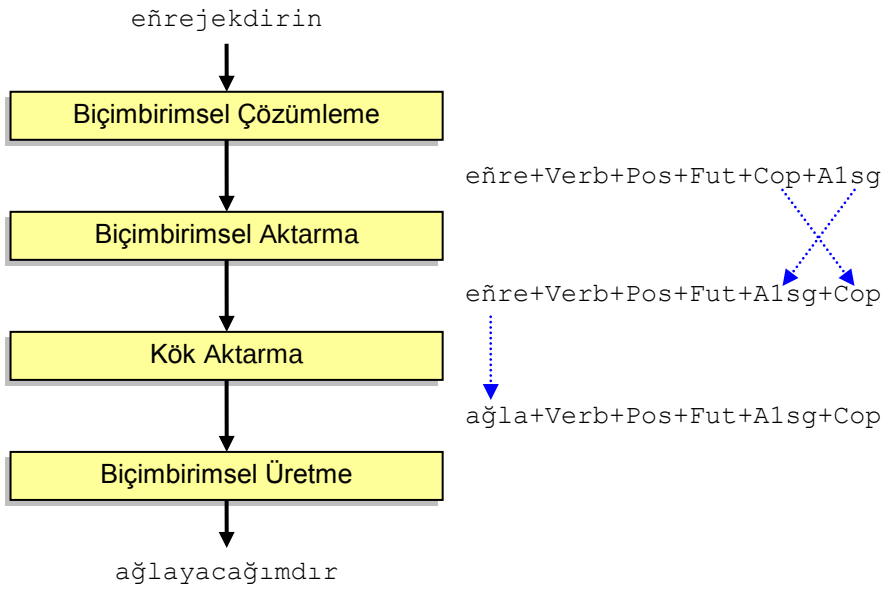

Şekil 6-1 : Örnek Türkmence sözcüğün Türkçe karşılığının oluşturulması

Geliştirilmiş doğrudan aktarım yönteminde dahi biçimbirimsel çözümleme ve sözcük kökü aktarımında belirsizlikler ortaya çıkacaktır. Bu belirsizliklerin çözülmesi, doğrudan aktarım yöntemini kullanan sistemlerde karmaşık kurallarla sağlanır (bkz. Bölüm 3.1.1). Bunun yerine, Bölüm 4'te önerilen ve doğrudan aktarım yaklaşımını istatistiksel yöntemlerle birleştiren modeller kullanılarak Türk dilleri arasında BÇ sistemleri gerçeklenebilir. Bu amaçla, Model 0 (temel model) üzerine gerçeklenmiş kuramsal bir çeviri sisteminin bileşenleri ve veri akışı Şekil 6-2'de verilmiştir. Bu şekilde kesikli çizgili dikdörtgenler veri kaynaklarını, düz çizgili dikdörtgenler ise süreçleri göstermektedir.

6.1. Kaynak Dilde Biçimbirimsel Çözümleme

Biçimbirimsel çözümleme, Türk dilleri gibi bitişken diller için doğal dil işleme alanında yapılacak her işlemde gerek duyulan bir aşamadır. Sözcüğün yüzeysel biçimlerinin sayısının çok fazla[6] olduğu diller için biçimbirimsel çözümleme olmadan aktarım sözlükleri hazırlamak ya da aktarım kuralları geliştirmek olanaksızdır. Dolayısı ile kaynak dil olarak hangi Türk dili seçilirse seçilsin, bu dil ile ilgili biçimbirimsel çözümleyicinin de hazırlanması gerekmektedir. Türkçe için geliştirilmiş geniş kapsamlı ve yüksek başarımlı bir biçimbirimsel çözümleyici

[6] Türkçe'de bir tek sözcük kökünden üretilebilecek yüzeysel biçimlerin sayısın milyondan fazladır

halihazırda bulunmaktadır [13]. Diğer Türk dilleri için bu tür bir çözümleyicinin varlığı (Kırım Tatarcası hariç) bilinmemektedir.

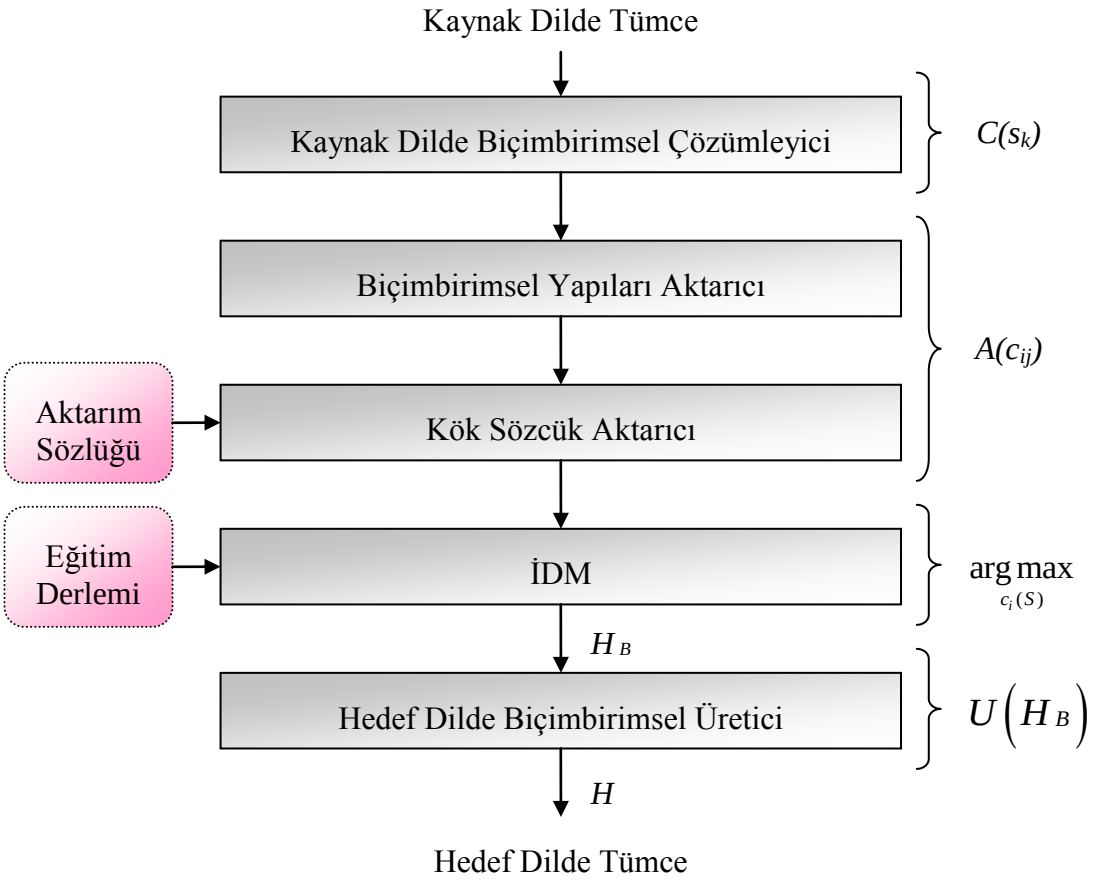

Şekil 6-2 : Temel modeli gerçekleyen örnek bir çeviri sistemi

Kaynak dil olarak seçilen dil, Türkçenin dışında bir Türk dili ise bu dil için bir biçimbirimsel geliştiricinin gerçeklenmesi ön koşuldur. Böyle bir gerçeklemede dikkat edilecek en önemli nokta, geliştirilecek çözümleyicinin var olan Türkçe biçimbirimsel çözümleyici ile benzer mantıkla çalışacak ve benzer biçimbirimsel etiketler üretecek şekilde tasarlanmasıdır. Bu sayede aktarım kuralları (yani *A* fonksiyonu) daha basit hale getirilebilir.

6.1.1. Kaynak Dilde Biçimbirimsel Belirsizliğin Giderilmesi

Türkçe gibi karışık bir biçimbirimsel yapıya sahip dillerde biçimbirimsel çözümleme sonuçları çoğu zaman birden fazladır. Bu ise **biçimbirimsel belirsizliğin** (morphological ambiguity) ortaya çıkmasına neden olmaktadır. Eğer kaynak Türk dili için biçimbirimsel belirsizliği gidermek üzere bir araç varsa, bu araç kullanılarak istatistiksel sürecin karmaşıklığı azaltılabilir.

Türkçe için biçimbirimsel belirsizliklerin giderilmesi ile ilgili birçok çalışma olmasına karşın [51-53] bu çalışmaların sonucunda yüksek başarımlı ve performansı yüksek bir araç henüz genel kullanıma sunulamamıştır. Diğer Türk dilleri için ise bu konuda bir çalışmaya rastlanamamıştır. Biçimbirimsel belirsizlik gidericilerin tasarlanması için kullanılan bir çok yöntem gözetimli (supervised) çalıştığı için elle işlenmiş çok miktarda eğitim verisine gerek duyulmaktadır. Türkçe dışındaki diğer Türk dilleri için henüz böyle bir eğitim kümesi olmamasından dolayı bilinen yöntemler kullanılarak bu diller için bir biçimbirimsel belirsizlik giderici tasarlanması yoluna gidilememektedir.

6.2. Sözcük Köklerinin Kaynak Dilden Hedef Dile Aktarımı

Kural tabanlı bütün bilgisayarlı çeviri sistemlerinde olduğu gibi öngörülen temel model için de bir aktarım sözlüğü gereklidir. Aktarım sözlüğünde kaynak dildeki sözcük bazında arama yapılabilmeli ve buna karşılık gelen hedef dildeki tüm sözcükler üretilebilmelidir. Bu noktada altı çizilmesi gereken konu, sözcük kökü aktarımı sırasında birden fazla karşılık üretilebileceğidir. Yani bu bileşenin ürettiği sonuçlar içerisinde bir belirsizlik vardır. Söz konusu bu belirsizlik **sözcüksel belirsizlik** (lexical ambiguity) olarak adlandırılmaktadır.

```
bar  ➔ var, bütün
```

Belirsizliği bir kademe azaltmak amacı ile sadece sözcük köküne bakarak arama yapmak yerine sözcük kökü ve sözcük türüne göre arama yapılabilir. Böylelikle yazımı aynı, ancak sözcük türleri farklı olan sözcük kökleri, daha az bir belirsizlikle aktarılabilir:

```
bar (sıfat)  ➔  bütün (sıfat)
bar (eylem)  ➔  var (eylem)
```

Aktarım sözlüğü tasarlanırken sözcük türlerine göre sınıflandırma yapılabilirse bu sayede belirsizliğin derecesi düşürülebilir.

6.3. Biçimbirimsel Yapıların Kaynak Dilden Hedef Dile Aktarımı

Kaynak ve hedef dil arasındaki biçimbirimsel farklılıkları gidermek üzere bir dizi dönüşümün yürütüldüğü aktarım bileşenidir. Bu dönüşüm, kaynak dildeki biçimbirimsel çözümleme sonucunda üretilen biçimbirimsel özelliklerin, hedef dil biçimbirimsel üreticinin beklediği şekile dönüştürme işlemi olarak da

nitelendirilebilir. Bu aşamada sözcük köküne dokunulmadan sadece biçimbirimsel etiketler üzerinde dönüştürme ve sıra değiştirme işlemleri yapılır. Bu kurallar, iki dil arasındaki biçimbirimsel farklılıklar incelenerek geliştirilir. Diğer bir yöntem ise birbirlerinin çevirisi olan, kaynak ve hedef dildeki biçimbirimsel yapıları içeren bir eğitim kümesi üzerinde, bilgisayar öğrenmesi yöntemlerinden birisinin eğitilerek kuralların otomatik olarak üretilmesidir.

6.4. İDM Bileşeni

Önerilen aktarım modellerinde yer alan bütün bileşenler içerisinde iki bileşenin çıktıları belirsizlik içermektedir: kaynak dilde biçimbirimsel çözümleyici ve kök aktarımı. Eğer bölüm 6.1.1'de anlatılan kaynak dilde biçimbirimsel belirsizlik giderici kullanılabilir durumda ise biçimbirimsel belirsizlik elenir ve sadece sözcüksel belirsizlik kalır.

Gerek biçimbirimsel belirsizlik, gerekse de sözcüksel belirsizliğin giderilmesini amaçlayan İDM bileşeni, istatistiksel yöntemlerle en olası sözcük dizisini (yani tümceyi) belirler. Bu amaçla Bölüm 2.3'de anlatılan İDM'ler kullanılmaktadır. Ancak gene Türk dillerinin türetme ve çekim özelliklerinden dolayı, İDM'ler salt biçimde kullanılamaz. Sözcüklerin sadece yüzeysel biçimlerini içeren bir İDM'de seyrek veri sorunu ortaya çıkmaktadır. Bunu önlemek için Bölüm 4.3'te anlatıldığı gibi farklı tiplerde İDM'lerin kullanılması yoluna gidilebilir.

Örneğin, sözcüklerin yüzeysel biçimleri yerine sadece sözcük kökleri üzerine kurulmuş bir İDM kullanılması durumunda, hedef dilde ortaya çıkan sözcüksel belirsizliğin giderilmesi sağlanabilir.

Aktarım sistemindeki İDM bileşenine girdi olarak, kaynak dildeki tümcenin bütün sözcüklerinin aday çevirileri gelir. Bileşenin çıktısı olarak ise tüm kombinasyonlar içerisinden seçilen İDM'ye göre en yüksek olasılığa sahip tümce üretilir.

Olası tüm kombinasyonların tamamının olasılıklarının hesaplaması yerine, aday sözcüklerden bir Hidden Markov Modeli (HMM) oluşturularak üzerinde Viterbi [54] algoritmasının çalıştırılmasıyla en yüksek olasılıklı sözcük dizisi elde edilebilir.

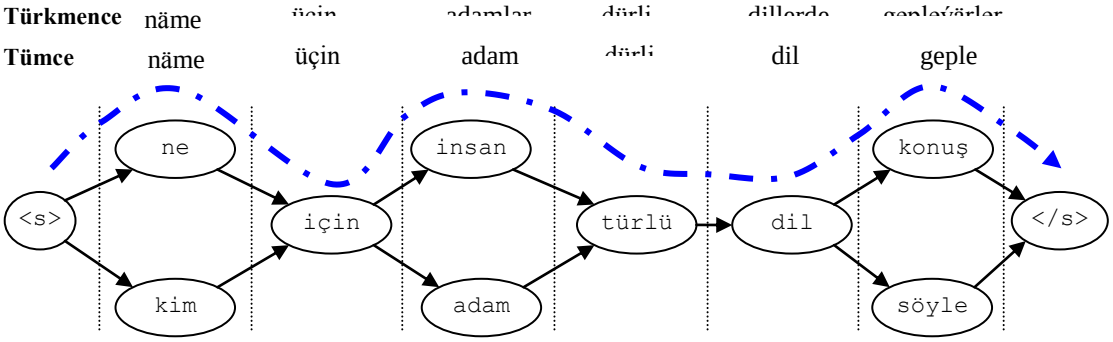

Şekil 6-3 : Örnek bir tümcenin HMM ile çözümlenme süreci

Yukarıda Türkmence bir tümce Türkçe'ye çevrilirken oluşturulan bir HMM örneği verilmiştir[7]. Şekil 6-3'teki özel simgeler **<s>** ile **</s>** sırasıyla tümce başını ve sonunu işaret eden simgelerdir. HMM'deki **gözlem olasılıkları** (observation probabilities) 1 seçilerek sadece durum geçiş olasılıklarının kullanılması sağlanmıştır [55]. Şekilde, durum geçişlerini gösteren oklara iliştirilmiş olarak, sözcüklerin seçilen İDM'ye göre olasılıkları bulunmaktadır. Örneğin ***"ne"*** ile ***"için"*** durumları arasındaki ok, *P("için"|"ne")* olasılığını, **<s>** ile ***"ne"*** arasındaki ok ise *P("ne"|<s>)* olasılığını (tümcenin başında ***"ne"*** sözcük kökünün olma olasılığını) göstermektedir. Viterbi algoritması ile de bu HMM üzerinde en olası yol (path) bulunur. Bu yol üzerindeki sözcükler seçilerek oluşturulan tümce hedef dilde olasılığı en yüksek çeviridir.

Tablo 6-2'de, Şekil 6-3'te kurulan HMM üzerinden hesaplanan en olası 3 aday tümce gösterilmiştir. Farklı derecelerde kök dil modelleri kullanılarak aday tümcelerin olasılıkları hesaplanmıştır. Kalın harflerle yazılan tümce, doğru çeviriyi göstermektedir [56].

Türkçe'de ***dil*** ismi ile birlikte ***söylemek*** yerine daha çok ***konuşmak*** eylemi kullanılmaktadır. Buna uygun olarak da tek başına sözcük sıklıklarına bakıldığında (*n=1*) ***söylemek*** eylemi ***konuşmak*** eyleminden daha çok geçmesine karşın İDM derecesi arttıkça ***konuşmak*** eylemini içeren tümcelerin olasılığının yükseldiği görülmektedir.

---

[7] Örnek HMM, 1. ve 2. dereceden İDM için geçerlidir. Daha yüksek İDM için geçmiş sözcük sayıları birden fazla olduğu için gösterilen modelin yükseltilmesi gereklidir.

Tablo 6-2 : İDM ile en olası tümcenin bulunması

İDM Derecesi	En Olası 3 Tümce	Sıra	Log. Olasılık
n=1	ne için insanlar türlü dillerde söylüyorlar	1	-17.2978
	ne için insanlar türlü dillerde konuşuyorlar	2	-17.5196
	ne için adamlar türlü dillerde söylüyorlar	3	-17.7816
n=2	**ne için insanlar türlü dillerde konuşuyorlar**	1	-18.1625
	ne için adamlar türlü dillerde konuşuyorlar	2	-18.3105
	kim için insanlar türlü dillerde konuşuyorlar	3	-18.6553
n=3	**ne için insanlar türlü dillerde konuşuyorlar**	1	-18.2265
	kim için insanlar türlü dillerde konuşuyorlar	2	-18.6196
	ne için adamlar türlü dillerde konuşuyorlar	3	-18.6294

6.5. Hedef Dilde Biçimbirimsel Üretici

İDM bileşeninin çıktısı, yüzeysel biçimdeki sözcükler yerine yapısal biçimdeki sözcüklerden oluşan bir tümcedir. Bu tümcede yer alan tüm sözcükler, hedef dile ilişkin ait bir biçimbirimsel üreticiden geçirilerek yüzeysel biçimler oluşturulmalı ve sistemin son çıktısı olan tümce üretilmelidir. Bu amaçla hedef dile ilişkin ait bir biçimbirimsel üreticiye gerek duyulmaktadır. Türkçe için geliştirilen biçimbirimsel çözümleyici, SDD olarak tasarlandığı için ters yönde çalıştırıldığında biçimbirimsel üretici olarak iş görmektedir [13]. Üstelik Türkçe için bu ters çalıştırma durumunda herhangi bir belirsizlik oluşmamaktadır. Yani yapısal biçimde bir sözcüğe karşılık, o sözcüğe ait sadece bir yüzeysel sözcük üretilmektedir [8]. Türkçe dışındaki diğer Türk dilleri için bilinen bir biçimbirimsel üretici yoktur.

[8] Çok ender bazı durumlarda birden fazla sonuç üretilmektedir:

`aç+Verb+Neg+Imp+A2sg` ➔ `(1) açma, (2) açmasana`

7. TÜRKMENCE'DEN TÜRKÇE'YE BİLGİSAYARLI ÇEVİRİ SİSTEMİ

Bir önceki bölümde ayrıntıları açıklanan çeviri modellerinin bir uygulaması olarak Türkmence'den Türkçe'ye bir çeviri sistemi tasarlanmış ve gerçeklenmiştir. Çeviri sistemi ilk olarak Model 0'a (temel model) uygun olarak gerçeklenmiş daha sonra ise bu temel model üzerine Model 1 ve Model 2'nin getirdiği iyileştirmeler eklenmiştir.

Gerçeklenen uygulamada, aktarım fonksiyonunda yer alan bütün bileşenler SDD biçiminde tasarlanmıştır.

7.1. Aktarım Modeli 0 Gerçeklemesi

Aktarım Modeli 0'ı temel alarak tasarlanan Türkmence'den Türkçe'ye çeviri sisteminin bileşen şeması Şekil 7-1'de verilmiştir:

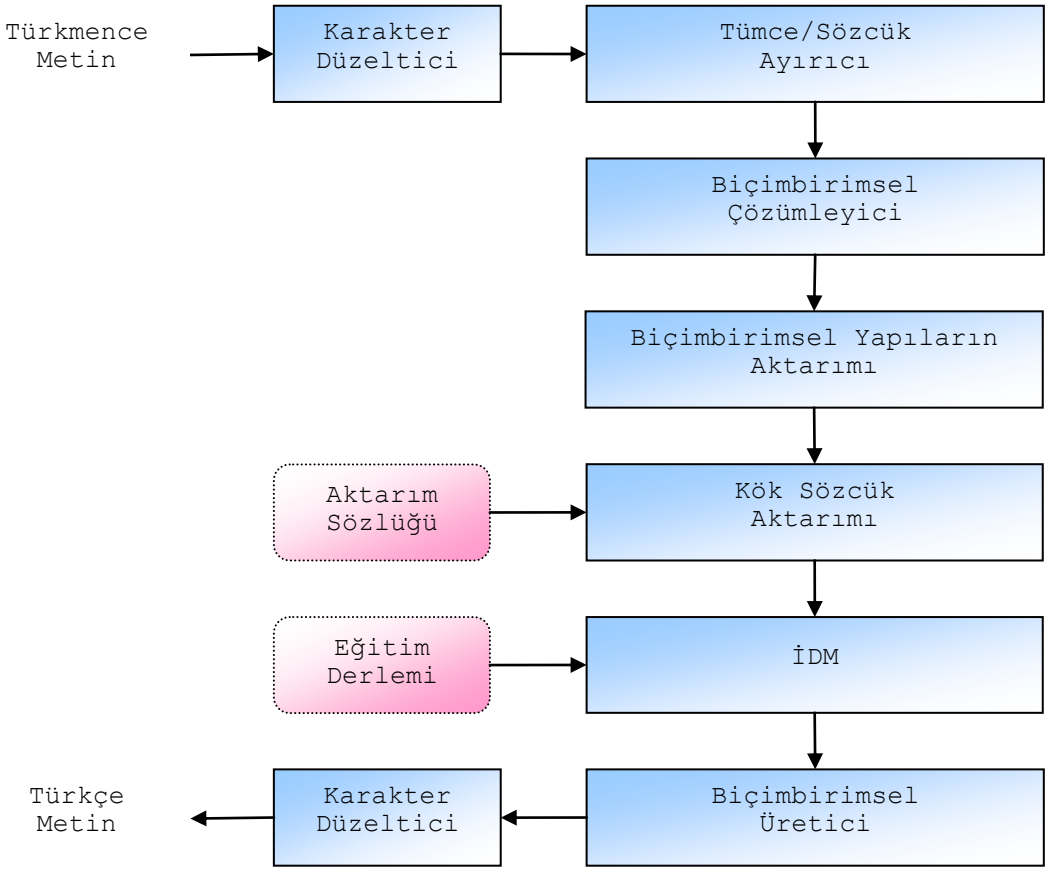

Şekil 7-1 : Aktarım Modeli 0 temelinde oluşturulan sistemin bileşenleri

7.1.1. Türkmence Biçimbirimsel Çözümleyicinin Geliştirilmesi

İki-düzeyli biçimbirimsel çözümleme ilkeleri esas alınarak Xerox sonlu durumlu araçlarıyla Türkmence için bir biçimbirimsel çözümleyici tasarlanmıştır [57]. Bu biçimbirimsel çözümleyicinin tasarım aşamaları aşağıdaki bölümlerde verilmiştir.

7.1.1.1. Türkmen Dilinin Biçimbirimsel Özellikleri

Türkmence dilinin biçimbirimsel yapısı Türkçe ile benzerlik göstermektedir. Özellikle isim çekimlerinde eklerin türleri ve geliş sıraları Türkçe'ye çok benzerdir. Bu benzerliklerden dolayı Türkçe için gerçeklenmiş olan biçimbirimsel çözümleyici [13] temel olarak alınmıştır.

Her ne kadar Türkmen'ce, Türkçe'ye en çok benzeyen dillerden birisi olsa da, iki dil arasında harfler, ses olayları, sözcük çekimleri ve anlamsal açıdan pek çok farklılıklar bulunmaktadır [58-63]. Türkmence'nin Türkçe'ye benzerliği ilk bakışta yararlı görülse de, bazı açılardan zararlı olmaktadır. Örneğin Türkçe ile birebir aynı olan bazı sözcükler ya da ekler, Türkmence'de farklı anlamlara gelmektedir. Türkçe bilen birisi, Türkmence öğrenirken bu tür yanılgılara kolayca düşebilmektedir.

Ses Olayları

Türkçe'ye en yakın dillerden biri olsa da Türkmence'de yazı dili ile konuşma dili arasında büyük farklılıklar bulunmaktadır. Aslında Türkçe'de de bütün sözcükler, yazıldığı gibi okunmaz ama Türkmence'de bu durum istisna olmaktan çıkmış ve çok sık karşılaşılan bir durum olmuştur. Maalesef kısıtlı sayıdaki Türkmence dilbilgisi kaynaklarının çoğunda, yazı dili ile konuşma dili arasındaki ayrım net olarak verilmemiştir. Bu nedenle bazı kuralların sadece konuşma dili için geçerli olduğunu ortaya çıkarmak oldukça zahmetli olmuştur.

Türkmence'de sözcüklerin okunuşları ile yazılışları arasında Türkçe'nin tersine çok büyük farklılıklar bulunmaktadır. Bütün seslilerin kısa ve uzun okunuşları bulunmaktadır. Ancak yazı dilinde herhangi bir seslinin kısa mı uzun mu okunacağına ilişkin bir işaret yoktur. Aşağıda bu konu ile ilgili örnekler verilmiştir (uzun okunan sesliler, ":" işaretiyle belirtilmiştir):

Uzun Okunuş			Kısa Okunuş		
at	*(a:t)*	ad, isim	**at**	*(at)*	at
ot	*(o:t)*	ateş	**ot**	*(ot)*	ot
daş	*(da:ş)*	taş	**daş**	*(daş)*	dış

Türkmence'de büyük ünlü uyumu vardır. Sözcüklerin bazıları küçük ünlü uyumuna uyarken bazıları da uymaz. Türkçe'de geniş-yuvarlak seslilerden (***o, ö***) sonra dar-yuvarlak (***u, ü***) ya da geniş-düz (***a, e***) seslileri gelir. Türkmence'de ise ***o, ö*** seslilerinden sonra dar-düz sesliler (***y, i***) gelir. Bu nedenle Türkmence'de bazı sözcükler küçük ünlü uyumuna uymaz.

Türkmence'de de Türkçe'de olduğu gibi sessiz yumuşaması vardır. Sözcük sonundaki ***p, ç, t, k*** sessizleri, sesli ile başlayan bir ek aldıklarında ***b, c, d, g*** harflerine dönüşürler. Sessiz benzeşmesi de kısmen görülür.

Sesli düşmesi kuralı ise Türkmence'de daha kurallıdır. Bir seslinin düşmesi için:

1. iki heceli sözcük olmalı
2. ilk V kısa, hece açık olmalı (V, CV)
3. ikinci hece kapalı olmalı (CVC)

Ancak ne yazık ki 2. maddede söylenin V'nin yani seslinin kısa olması, yazı dilinde belirtilmemektedir.

Okunuşlarla ilgili bir çok kurala, biçimbirimsel çözümleyicinin geliştirilmesi ile ilgisi olmadığı için burada yer verilmeyecektir.

Tekillik / Çoğulluk

Çoğulluk ekleri ***+lar*** ve ***+ler*** Türkçe'deki ile aynı şekilde kullanılır.

Belirtme Durumu

Belirtme durumu eki Türkçe'dekinden farklı olarak sadece ***+y*** ve ***+i*** eklerinden oluşmaktadır. Ancak Türkçe'de ekten önce sesli harf bulunursa araya ***n*** harfi yerine ***y*** harfi gelir:

```
kitaby (kitabı)        goly (kolu)       başy(başı)
gözi   (gözü)          güli (güli)
```

Yönelme Durumu

Türkçe'deki gibi ***+a*** ve ***+e*** ekleri ile kurulur.

```
depdere (deftere)   göze(göze)          bilbile (bülbüle)
```

Sesli ile biten isimlerde, yaklaşma durumu eki (***+a, +e, +ä***) farklılık göstermektedir.

i) ***–a, –o*** ile biten sözcüklere yaklaşma durumu eki eklenmez, yaklaşma durumu sadece sözcüğün sonunda seslinin uzun okunuşu ile belirtilir.

ata *(ata) baba*

ata *(ata:) babaya*

ii) ***–i, –e, –ä*** ile biten sözcüklere yaklaşma durumu eki geldiğinde, sözcüğün son seslisi ***–ä*** olarak değişir.

Berdi ⇒ Berdä *Berdi ⇒ Berdi'ye*

iii) ***–y*** seslisi ile biten sözcüklere yaklaşma durumu eki geldiğinde, sözcüğün son seslisi ***–a*** seslisi olarak değişir.

Mary ⇒ Mara *Marı ⇒ Marı'ya*

Kalma Durumu

Türkçe'dekine benzer olarak ***+da, +de*** ekleri ile kurulur. Türkçe'deki kullanımdan tek farklı bu eklerin ünsüz benzeşmesine uymamasıdır (***+ta, +te*** halleri yoktur):

```
guşda (kuşta)       altda (altta)       kitapda (kitapta)
```

Kalma durumundan sonra ***–ki*** eki gelirse, kalma durumu ekindeki sesli uzar:

```
depderdäki (defterdeki)     bizdäki (bizdeki)   süýtdäki (sütteki)
kitapdaki (kitapdaki)       adamdaki (adamdaki) ondaki (ondaki)
```

Çıkma Durumu

Çıkma durumu, ***+dan*** ve ***+den*** ekleri ile kurulur. Bu ekler de ünsüz benzeşmesine uymazlar:

```
öýden (evden)       altdan (alttan)         kitapdan (kitaptan)
```

Tamlayan Durumu

Tamlayan durumu ekleri ***+yñ, +iñ, +uñ*** ve ***+üñ*** ekleridir:

```
goluñ (kolun)    burnynyñ (burnunun)        diliñ (dilin)
```

İsim çekimi ve eylem çekimi açısından incelendiğinde, Türkmence, isim çekimi yönünden Türkçe'ye çok benzerken, eylem çekiminde ciddi farklılıklar vardır. Özellikle çatı kurulumu Türkmence'de Türkçe'ye oranla çok daha karmaşıktır. Türkçe'de çatı kurulumu genelde aşağıdaki gibidir:

```
görmek            (Yalın)
görüşmek          (İşteş)
görüştürmek       (İşteş-Ettirgen)
görüştürülmek     (İşteş-Ettirgen-Edilgen)
```

Sadece bazı durumlarda ettirgenlik birkaç defa tekrarlanabilir.

Türkmence'de ise çatı eklerinin geliş sırası çok daha karışıktır:

Tablo 7-1 : Türkmence'de çatı eklerinin sıralanışı

İki Çatı Ekli Eylemler	**Üç Çatı Ekli Eylemler**	**Dört Çatı Ekli Eylemler**
Ettirgen + Dönüşlü	Dönüşlü + Ettirgen + Edilgen	Dönüşlü + İşteş + Ettirgen + Edilgen
Dönüşlü + Edilgen	İşteş + Ettirgen + Edilgen	Ettirgen + Dönüşlü + Ettirgen + Edilgen
İşteş + Edilgen	Ettirgen + Edilgen + İşteş	
Ettirgen + Edilgen	Dönüşlü + Ettirgen + İşteş	
Dönüşlü + İşteş	Dönüşlü + İşteş + Ettirgen	
Edilgen + İşteş	Edilgen + İşteş + Ettirgen	
Ettirgen + İşteş	Ettirgen + İşteş + Ettirgen	
İşteş + İşteş	Dönüşlü + Ettirgen + Ettirgen	
Dönüşlü + Ettirgen		
İşteş + Ettirgen		
Ettirgen + Ettirgen		

Ayrıca Türkmence'de bazı eylem kipleri çekilmezler. Örneğin gelecek zamanı belirten ***+jek / +jak*** ekinden sonra kişi çekim eki gelmez. Örnek kullanımı aşağıdaki gibidir:

```
Men geljek (geleceğim)
Sen geljek (geleceksin)
O geljek   ([o] gelecek)
```

Ayrıca gereklilik kipi ***+malı / +meli*** de benzer şekilde kişi eki almaz.

Ancak bu kiplere kesinlik anlamı katan ***+dyr*** eki geldiğinde, bu ***+dyr*** ekinden sonra kişi çekim ekleri gelebilir.

```
Men geljekdirin.  (geleceğimdir)
```

Türkmence'de, Türkçe'de bulunmayan bazı kipler de vardır. Örnek olarak bir iş için hazırlık yapıldığını ya da o işin yapılmasının düşünüldüğünü gösteren ***+mekçi / +makçy*** eki bulunmaktadır. Bu ek de istisna olarak çekim eki almayan kipler grubundandır.

Belirsiz geçmiş zaman eki olarak kullanılan ***+mış / +miş*** eki Türkmence'de ilk zaman olamaz. Bunun yerine ***+ypdy / +ipdi / +updu / +üpdü*** ekleri gelmektedir. Ancak ikinci zaman olarak ***+mış / +miş*** eki gelebilmektedir.

Türkçe'de geniş zaman olarak kullanılan ***+ar / +er*** eki, Türkmence'de gelecek zaman anlamını taşımaktadır.

Gene Türkçe'dekine benzer şekilde geniş zamanın 3. tekil şahsının olumsuzu farklıdır. Ancak daha büyük bir farklılık olarak bazı kiplerde olumsuzluk eki olarak ***+ma / +me*** gelmemekte bunun yerine eylemden sonra ***däl*** ("değil") getirilmektedir. Örnek:

```
Men gelcek däl
```

Kimi durumlarda ***däl*** eylemi de çekime uğramaktadır.

Biçimbirimsel Çözümleyicinin Gerçeklenmesi

Türkmence için biçimbirimsel çözümleyici geliştirirken iki düzeyli biçimbirimsel çözümleme yöntemi benimsenmiş ve *XEROX*'un sonlu durumlu araçlarından yararlanılmıştır [23]. Öncelikle kökler ve eklerle ilgili durum geçişleri yani morfotaktik kurallar tasarlanmış ve *LEXC* aracılığıyla gerçeklenmiş, daha sonra iki-düzeyli kurallar *TWOLC* ile oluşturulmuştur. Ek olarak, bazı geçersiz durumların elenmesi için *XFST* ortamında kurallar yazılmış ve elde edilen bu üç SDD birleştirilerek tek bir SDD elde edilmiştir. Oluşan bu çözümleyici, ters yönde çalıştırıldığı zaman üretici olarak da çalışabilmektedir.

7.1.1.2. İki Düzeyli Kurallar

Türkmence'deki çeşitli ses olaylarını ve değişimlerini gerçeklemek için bir dizi iki-düzeyli kural tanımlanmış ve *TWOLC* derleyicisi yardımı ile bu kuralları gerçekleyen bir SDD oluşturulmuştur.

İki düzeyli kuralları tanımlamadan önce, bu kuralların üzerinde işlem göreceği abecenin tanımlanması gerekmektedir. Bu abece güncel Türkmen harfleri ile sadece ara aşamalarda kullanılan ve yazıda görünmeyen bazı ek karakterler içermektedir.

Her ne kadar *TWOLC* derleyicisi UTF-8 karakter kümesini destekleyerek standart olmayan ASCII karakterlerinin kullanımına izin verse de, bu tür bir kullanımda hata ayıklama ve komut satırından sınamaların yapılması olanaksız olmaktadır. Bu nedenle standart ASCII tablosunda olmayan karakterler için bir ASCII karakteri, Tablo 7-2'deki gibi seçilmiş ve kurallarda bu şekilde gösterilmiştir.

Tablo 7-2 : ASCII olmayan karakterler yerine kullanılan karşılıklar

ASCII dışı karakterler	***ü***	***ö***	***Ç***	***ñ***	***ş***	***ý***	***ź***	***ä***
Seçilen ASCII karşılık	***U***	***O***	***C***	***N***	***S***	***Y***	***Z***	***E***

Ayrıca kuralların üzerinde işlem göreceği bir takım kümeler de tanımlanmıştır:

```
! Sessiz harfler
CONS =    b C d f g h j Z k l m n N p r s S t w Y z;

! Sesli harfler
VOWEL =   a E e y i o O u U;

! Kalın sesliler
BACKV =   a y u o;

! İnce sesliler
FRONTV =  e E i O U;

! Kalın-yuvarlak sesliler
BKROV =   o u;

! Kalın-düz sesliler
BKUNROV = a y;

! İnce-yuvarlak sesliler
FRROV =   O U;

! İnce-düz sesliler
FRUNROV = e i E;

! Bazı durumlarda silinen harfler (kaynaştırma gibi)
X =       s M n %$;

! Sesli düşmesine uğrayabilecek harfler (burun->burnu gibi)
VS =      y i O o U u;
```

Sesli düşmesi, sessiz yumuşaması gibi ses olaylarını gerçekleyebilmek için çeşitli Türkmence kaynaklarından çıkartılan bir dizi kural hazırlanmıştır [58, 61, 63].

```
1. A:a =>  [:BACKV]  [:CONS]* (%':%') (%+:0) [CONS: | :CONS | :0]* _
2. A:e =>  [:FRONTV] [:CONS]* (%':%') (%+:0) [CONS: | :CONS | :0]* _
```

Bu iki kural ile eklerde ***A*** ile belirtilen sesli harfin, ünlü uyumuna göre ***a*** ya da ***e*** harfine dönüştürülmesi sağlanmıştır.

```
Yapısal biçim     : galam+Noun+A3pl+Pnon+Nom
```

```
Ara biçim         : galam+lAr
Yüzeysel biçim    : galam0lar
                    galamlar  (kalemler)

Yapısal biçim     : depder+Noun+A3pl+Pnon+Nom
Ara biçim         : depder+lAr
Yüzeysel biçim    : depder0ler
                    depderler (defterler)

3. V:a  =>  [:BACKV]  [CONS]* (%+:0) [CONS: | :CONS | :0]* _
4. V:E  =>  [:FRONTV] [CONS]* (%+:0) [CONS: | :CONS | :0]* _
```

Bu iki kural ile eklerde ***V*** ile belirtilen sesli harfin, ünlü uyumuna göre ***a*** ya da ***E*** (***ä***) harfine dönüştürülmesi sağlanmıştır.

```
Yapısal biçim     : bar+Verb+Pos+Prog2+Anon
Ara biçim         : bar+YVn
Yüzeysel biçim    : bar0Yan
                    baryán    (varmakta olan)

Yapısal biçim     : geple+Verb+Pos+Prog2+Anon
Ara biçim         : geple+YVn
Yüzeysel biçim    : geple0YEn
                    gepleýän  (konuşmakta olan)

5. I:y  =>  [:BACKV]  [CONS]* (%':%') (%+:0) [CONS: | :CONS | :0]* _
6. I:i  =>  [:FRONTV] [CONS]* (%':%') (%+:0) [CONS: | :CONS | :0]* _
```

Bu iki kural ile eklerde ***I*** ile belirtilen sesli harfin, ünlü uyumuna göre ***y*** ya da ***i*** harfine dönüştürülmesi sağlanmıştır.

```
Yapısal biçim     : gol+Noun+A3sg+P1pl+Nom
Ara biçim         : gol+HmIz
Yüzeysel biçim    : gol0umyz
                    golumyz   (kolumuz)

Yapısal biçim     : Col+Noun+A3sg+P1pl+Nom
Ara biçim         : Col+HmIz
Yüzeysel biçim    : Col0Umiz
                    çölümiz   (çölümüz)

 7. H:i =>  [:FRUNROV] [CONS]* (%':%') (%+:0) [CONS: | :CONS | :0]* _
 8. H:y =>  [:BKUNROV] [CONS]* (%':%') (%+:0) [CONS: | :CONS | :0]* _
 9. H:u =>  [:BKROV]   [CONS]* (%':%') (%+:0) [CONS: | :CONS | :0]* _
10. H:U =>  [:FRROV]   [CONS]* (%':%') (%+:0) [CONS: | :CONS | :0]* _
```

Bu kurallar ile eklerde ***H*** ile belirtilen sesli harfin, kendinden önce gelen seslinin incelik-kalınlık ve yuvarlaklık-düzlük özelliklerine göre ***i, y, u*** ya da ***U*** harflerinden birine dönüştürülmesi sağlanmıştır.

```
Yapısal biçim     : dogan+Noun+A3sg+P1pl+Nom
Ara biçim         : dogan+HmIz
Yüzeysel biçim    : dogan0ymyz
                    doganymyz (kardeşimiz)

Yapısal biçim     : depder+Noun+A3sg+P1pl+Nom
Ara biçim         : depder +HmIz
```

```
Yüzeysel biçim    : depder0imiz
                    depderimiz (defterimiz)

Yapısal biçim     : suw+Noun+A3sg+P1pl+Nom
Ara biçim         : suw+HmIz
Yüzeysel biçim    : suw0umyz
                    suwumyz   (suyumuz)

Yapısal biçim     : sOz+Noun+A3sg+P1pl+Nom
Ara biçim         : sOz+HmIz
Yüzeysel biçim    : sOz0Umiz
                    sözümüz   (sözümüz)
```

```
11. H:0  <=>   [:VOWEL] %+:0 _
```

Eğer ***H*** ile başlayan bir ek, sesli ile biten bir gövdeye eklenirse, bu ***H*** sesi silinir.

```
Yapısal biçim     : kEdi+Noun+A3sg+P1sg+Nom
Ara biçim         : kEdi+Hm
Yüzeysel biçim    : kEdi00m
                    kädim     (kabağım)
```

```
12. T:a <=> [:BACKV]  [CONS: | :CONS | :0]+ [%+:0] _
13. T:e <=> [:FRONTV] [CONS: | :CONS | :0]+ [%+:0] _
14. Cx:Cy <=> _%+:0 [T:] where Cx in (i e A y)
                               Cy in (E E E a) matched
```

Türkmence'de yönelme durumu (dative case), sıra dışı bir durumdur. Eğer son hecesinde kalın sesli içeren ve sessiz ile biten bir gövdeye eklenirse yönelme durumu eki ***a***, son hecesinde ince sesli içeren ve sessiz ile biten bir gövdeye eklenirse yönelme durumu eki ***e*** olur. Eğer eklendiği gövde sesli ile bitiyorsa, yönelme hali eki, gövdenin son seslisini (***i⇨E, e⇨E, A⇨E, y⇨a*** şeklinde) değiştirir.

```
Yapısal biçim     : Berdi+Noun+A3sg+Pnon+Dat
Ara biçim         : Berdi+T
Yüzeysel biçim    : BerdE00
                    Berdä     (Berdi'ye)

Yapısal biçim     : Mary+Noun+A3sg+Pnon+Dat
Ara biçim         : Mary+T
Yüzeysel biçim    : Mara00
                    Mara      (Marı'ya)

Yapısal biçim     : ata+Noun+A3sg+Pnon+Dat
Ara biçim         : ata+T
Yüzeysel biçim    : ata00
                    ata       (babaya)
```

Son örnekten de görüldüğü gibi Türkmence'de, sonu ***a*** ile biten gövdelerin yönelme durumu ile yalın durumu yazılış olarak aynıdır, farklılık okunuşta belli edilir.

```
15. e:E <=>  _ %+:0 [H:] [m: | N: | p:] (I: z:); _ %+:0 [H:] b e r;
```

Bu kural, ***e*** harfi ile biten bir gövdeye bazı ekler geldiğinde, gövdenin sonundaki ***e*** harfinin yumuşayarak ***E*** sesine dönüşmesini sağlar.

```
Yapısal biçim     : iSle+Verb+Pos+Past+A3sg
Ara biçim         : iSle+HpdI
Yüzeysel biçim    : iSlE00pdi
                    işläpdi          (istemişti)
```

```
16. Cx:Cy <=> [:CONS] %+:0 _ (CONS VOWEL);where Cx in (s n S Y)
                                             Cy in (0 0 s 0) matched;
```

Gövdenin sonunda sessiz varsa, gövdeye gelecek ekin başındaki ***s, n, Y*** harfleri silinir, ***S*** ise silinmeyerek ***s***'ye dönüştürülür (kaynaştırma harfi olarak kullanılmayan ve silinmemesi gereken ***s*** anlamında kullanılmaktadır).

```
17. A:E => %+:0 m _ [k:] %+:0 [T:]; %+:0 d _ %+:0 k [I:];
```

İki özel durumda eklerdeki ***A*** harfi ***E*** olarak çözümlenir. Bunlardan bir tanesi, eylem kökünün ***+mAk*** mastar eki ile isim haline dönüşerek yönelme durumda kullanıldığı durumdur. İkincisi ise isim çekiminde bulunma hali eki ***+dA***'dan sonra ***+kI*** ekinin geldiği durumdur. Her iki durumda da ***A*** harfi ***E*** olarak çözümlenir.

```
Yapısal biçim     : ber+Verb+Pos^DB+Noun+Inf1+A3sg+Pnon+Dat
Ara biçim         : ber+mAk+T
Yüzeysel biçim    : ber0mEg0e
                    bermäge          (varmaya)

Yapısal biçim     : galam+Noun+A3sg+Pnon+Dat
Ara biçim         : galam+dA+kI
Yüzeysel biçim    : galam0dE0ki
                    galamdäki        (kalemdeki)
```

```
18. Cx:Cy => _ %+:0 (X:0) [ :VOWEL ]; where Cx in (p t C k)
                                            Cy in (b d j g) matched;
```

Ünsüz yumuşamasını gerçekleyen bu kural, sert sessizler ***p, t, C*** ve ***k*** ile biten gövdelere sesli ile başlayan bir ek gelirse, bu sert sessizlerin yumuşamasını sağlar.

```
Yapısal biçim     : kitap+Noun+A3sg+Pnon+Dat
Ara biçim         : kitap+T
Yüzeysel biçim    : kitab0a
                    kitaba           (kitaba)
```

```
19. VS:0 <=> %$:0 _  [ CONS %+:0 (X:0) [A: | H: | I: | T:] ];
20. H:0  <=> %$:0 _  [ CONS %+:0 (X:0) [A: | H: | I: | T:] ];
```

Bazı sözcüklerin köklerindeki bazı harfler, belirli ekler geldiğinde düşerler. Bunun belirli bir kuralı olmadığı için, düşmesi olası bu harflerden önce alt sözlüklerde ***$*** işareti konularak bu durum belirtilir. Yüzeysel biçime dönüştürülürken ***$*** işareti silindiği için yüzeysel biçimde ***$*** işareti görünmemektedir.

7.1.1.3. Morfotaktik Kurallar

Morfotaktik kurallar, geçerli bir sözcük oluşturmak için eklerin geliş sıralarını inceleyen ve modelleyen kurallardır [64]. Morfotaktik kurallar da, tıpkı iki-düzeyli kurallar gibi SDD'ler ile gerçeklenmiştir. Oluşturulan sonlu durum makineleri Şekil 7-2 ve Şekil 7-3'de verilmiştir. Bu şekillerde kutular durumları, oklar ise durum geçişlerini göstermektedir. Durum geçişleri sadece okların üzerindeki eklerden bir tanesi geldiğinde yapılmaktadır. Durum geçişlerindeki ***"0"*** ifadesi, herhangi bir ek gelmeden yapılabilen boş geçişi belirtmektedir. Şekildeki yuvarlaklar, geçerli bir sözcük oluştuğu zaman ulaşılan bitiş durumlarıdır. Oluşan sözcüğün son sözcük sınıfı, bitiş durumlarının yanında parantez içerisinde belirtilmiştir. Tasarımı yapılan bu sonlu durumlu makinelerin oluşturulması için XEROX LEXC aracı kullanılmıştır. Buna uygun olarak, durumlar için alt sözlükler tanımlanmıştır. Her alt sözlük, iki sütundan oluşmaktadır. İlk sütunda birbirinden ***:*** işareti ile ayrılmış biçimde sözcük kökünün ya da ekin yüzeysel ve yapısal biçimleri bulunur. Eğer her iki biçimin yazılışı da aynı ise araya ***:*** işareti konulmadan bir defada yazılır (***geple:geple*** şeklinde yazılmadan sadece ***geple*** yazılır). İkinci sütunda ise bir sonraki durum yani alt sözlük belirtilir. Geliştirilen sonlu durumlu dönüştürülerden alınan bir kesit aşağıda verilmiştir:

```
LEXICON VERBS
diy         VERB-POST;
bil         VERB-POST;
geple       VERB-POST;
…

LEXICON VERB-POST
+Verb : 0   VERB-ROOT;

LEXICON VERB-ROOT
0       : 0         VERB-PASSIVE;
+Recip : +nHS       VERB-RECIP;
+Recip : +S         VERB-RECIP;
…

LEXICON VERB-PASSIVE
0 : 0                          VERB-MAIN;
^DB+Verb+Hastily : +Hber       VERB-MAIN;
^DB+Verb+Recip   : +nHS        VERB-RECIP;

LEXICON VERB-MAIN
+Pos : 0          VERBAL-STEM;
+Neg : +mA        VERB-NEG;
…

LEXICON VERBAL-STEM
+Narr : +Hp       VERB-PAST-2;
```

```
+Past : +dH       VERB-PAST;
+Opt  : +VYAdI    VERB-PAST;
+Desr : +SA       VERB-COND;
+Imp  : 0         VERB-IMPERATIVE;
+Prog1 : +YVr     VERB-PROG;
…
```

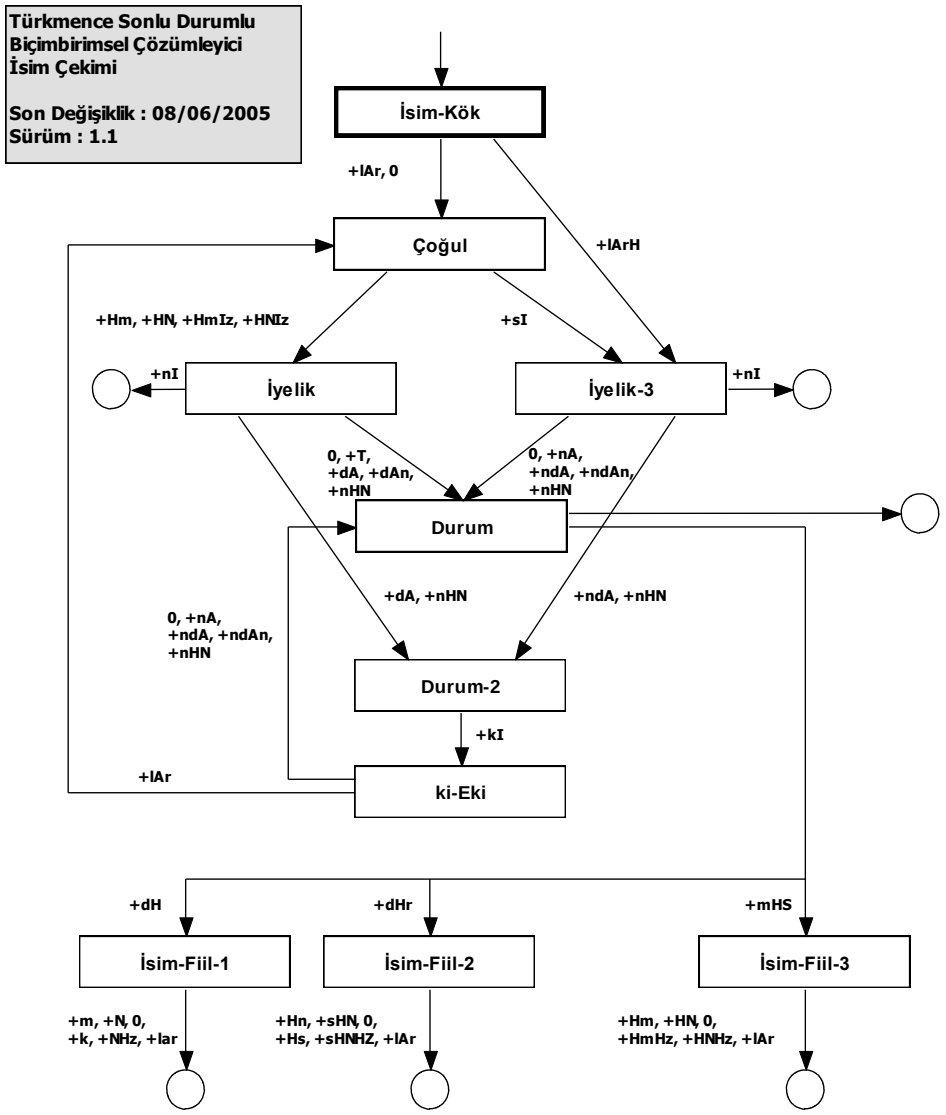

Şekil 7-2 : İsim soylu sözcükler için morfotaktik kuralların sonlu durum makinesi

Şekil 7-3 : Eylem soylu sözcükler için morfotaktik kuralların sonlu durum makinesi

7.1.2. Kök Sözcük Aktarım Kuralları

Biçimbirimsel çözümlemesi yapılmış Türkmence sözcük köklerinin Türkçe'ye aktarılmasını sağlayan kurallar, SDD'ler ile gerçeklenmiştir. Örnek bir aktarım kuralı aşağıda verilmiştir:

```
"tatlı" <- "Yakymly"
```

Bölüm 6.2'de belirtildiği gibi, bu aktarım kurallarında sözcük türlerinin kullanılması, sözcüksel belirsizliği azaltmaktadır. Yazılan kurallar bu ilke çerçevesinde oluşturulmuş ve kuralların sağ bağlamları sözcük türleri ile kısıtlandırılmıştır:

```
"gri" <- "boz" \/  _ "+Adj"   .o.
"sil" <- "boz" \/  _ "+Verb"
```

Bu sayede sistemin rastladığı bütün "***boz***" köklerini, "***gri***" ve "***sil***" kökleri ile değiştirmesinin önüne geçilerek, aktarılacak sözcüğün sıfat ya da eylem olma durumuna göre sadece uygun karşılıkların dönüştürülmesi sağlanmıştır. Kök aktarım bileşenin örnek girdisi ve çıktısı aşağıdaki şekilde verilmiştir:

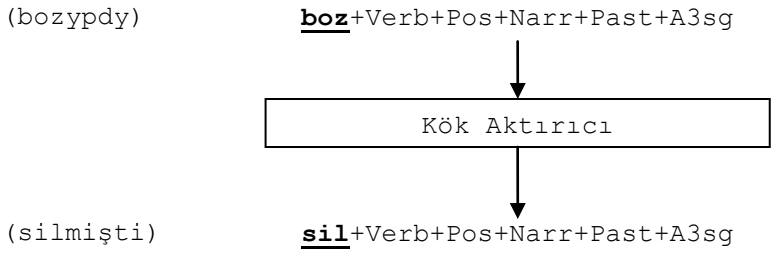

Şekil 7-4 : Kök aktarım bileşeni

7.1.2.1. Birden Fazla Sözcükten Oluşan Karşılıklar

Dillerin doğası gereği, Türkmence'de bir tek sözcükle ifade edilen bazı kavramlar Türkçe'de bir tek sözcük ile ifade edilememekte, ancak iki ya da daha fazla sözcükten oluşan ÇSG'ler ile ifade edilebilmektedir. Bu durumda kök değiştirmek yerine daha akıllı bir yönteme başvurulması gereklidir. Bu tür durumlara örnek olarak aşağıdaki sözlük girdileri gösterilebilir:

Türkmence	Türkçe

```
--------------------------------
boşatmak          özgür bırakmak
dillenmek         dile gelmek
entegem           uzun süre
```

Hedef dil karşılığı ÇSG olan sözlük girdileri için standart kök aktarım kuralları yerine gelişmiş kuralların oluşturulması gereklidir. Önemli olan bir diğer nokta da, bu değiştirme sürecinde, ÇSG'nin son sözcüğü hariç bütün sözcüklerin yapısal biçimde olması zorunluluğudur. Bu, hedef dilde üretilecek tüm sözcüklerin biçimbirimsel özelliklerinin de bulunması zorunluluğu anlamına gelmektedir çünkü sistemin diğer bileşenleri yürütülürken, sözcüklerin yapısal biçimlerine gerek duymaktadır.

Türkçe'de ÇSG'lerin türetme ve/veya çekim eklerinden etkilenen kısmı sadece ÇSG'nin sonunda yer alan sözcüktür [45]. Bu gerçekten hareketle, kaynak dildeki sözcüğe ait biçimbirimsel özelliklerin, hedef dildeki ÇSG'nin sonundaki sözcüğe ait olduğu, ÇSG'nin başında yer alan diğer sözcüklerin sabit bir yapıya sahip olduğu sonucuna varılabilir. Bu koşullarla, yukarıdaki sözlük girdilerini aktarmak üzere oluşturulması gereken kurallar aşağıda verilmiştir:

```
"dil+Noun+A3sg+Pnon+Dat gel" <- "dillen"
"özgür+Adj bırak" <- "boSat"
"uzun+Adj süre+Noun+A3sg+Pnon+Nom"<-"entegem+Adverb"
```

Aşağıdaki şekilde ise kök aktarıcının örnek bir ÇSG'yi aktarması gösterilmiştir. Altı çizili olmayan Türkmence biçimbirimsel yapıların, ÇSG'nin son sözcüğüne eklendiği görülmektedir.

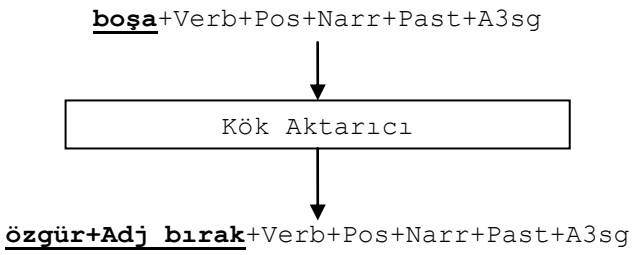

Şekil 7-5 : ÇSG'lerin Aktarılması

7.1.2.2. Sözcüksel Aktarım Kuralları

Uygulamada ortaya çıkan bazı durumlar göstermiştir ki bir takım sözcükler için sadece sözcük kökünü değiştiren basit bir kural yeterli olmamaktadır. Örneğin Türkmence'deki ***ulumsy*** sözcüğü Türkçe'deki ***kibirli*** sözcüğünün karşılığıdır.

Standart kurallar uygulanarak sadece sözcük kökü değiştirildiğinde aşağıdaki dönüştürme işlemi gerçeklenir:

```
kibirli+Adj  ←  ulumsy+Adj
```

İlk bakışta göze çarpan herhangi bir sorun olmamasına karşın, oluşan yapısal biçimdeki sözcük, Türkçe biçimbirimsel üretici tarafından yüzeysel biçime dönüştürüleceği zaman herhangi bir çıktı üretilememektedir. Bunun altında yatan neden ise, Türkçe'deki ***kibirli*** sözcüğünün aslında türemiş bir sözcük olması ve bu sözcüğün doğru yapısal biçiminin aşağıdaki gibi olmasıdır:

```
kibir+Noun+A3sg+Pnon+Nom^DB+Adj+With
```

Ortaya çıkan bu sorunun düzeltilmesi için, Türkmence'deki ***ulumsy*** sözcüğü için aşağıdaki gibi özel bir kural oluşturulmalıdır:

```
"kibir+Noun+A3sg+Pnon+Nom^DB+Adj+With"<-"ulumsy+Adj"
```

Örnekte açıklandığı gibi sözcüğe bağlı özel durumları kotaran kurallar, **sözcüksel kurallar** (lexicalized rules) olarak adlandırılmıştır.

Ancak her iki dilde de ortak olan türetme ekleri ile türetilebilecek sözcükler için ayrı kuralların oluşturulmasına gerek yoktur. Örneğin Türkmence'deki ***+lyk*** eki ile Türkçe'deki ***+lık*** eki, sıfattan isim yapan aynı göreve sahip iki yapım ekidir. Dolayısı ile Türkmence'de bulunan ***ulumsylyk*** sözcüğünün karşılığı da ***kibirlilik*** sözcüğüdür. Her iki sözcüğün biçimbirimsel çözümlemesi aşağıda belirtilmiştir:

```
ulumsy+Adj^DB+Noun+Ness+A3sg+Pnon+Nom
kibir+Noun+A3sg+Pnon+Nom^DB+Adj+With^DB+Noun+Ness+A3sg+Pnon+Nom
```

Örnekten de görüldüğü gibi, kalın ve altı çizili olarak gösterilmeyen biçimbirimsel yapılar aynıdır. Dolayısı ile bu iki sözcük için ayrı bir sözcüksel aktarım kuralı hazırlanmasına gerek yoktur, yukarıda anlatılan ve ***ulumsy*** sözcüğünü aktaran sözcüksel aktarım kuralının çalışması yeterli olmaktadır.

7.1.3. Biçimbirimsel Aktarım Kuralları

Türkmence ve Türkçe arasındaki biçimbirimsel farklılıkların giderilerek Türkmence biçimbirimsel çözümleme sonucu üretilen yapıların, kabul edilebilir Türkçe biçimbirimsel yapılara dönüştürülmesini sağlayan kurallardır.

Örneğin Türkmence'de bulunan ve emir kipinin 1. tekil ve 1. çoğul kişiler için çekimi, Türkçe'de istek kipine karşılık gelmektedir:

```
Türkmence                          Türkçe Karşılığı
-------------------------------------------------------------------
alaYyn (al+Verb+Pos+Imp+A1sg)    alayım (al+Verb+Pos+Opt+A1sg)
algyn  (al+Verb+Pos+Imp+A2sg)    al     (al+Verb+Pos+Imp+A2sg)
alsyn  (al+Verb+Pos+Imp+A3sg)    alsın  (al+Verb+Pos+Imp+A3sg)
```

Bu değişikliği sağlamak üzere aşağıdaki kural geliştirilmiştir:

```
define FromImpToOptA1sgA1pl  "+Opt+A1sg" <- "+Imp+A1sg" .o.
                             "+Opt+A1pl" <- "+Imp+A1pl";
```

Her iki dil arasındaki biçimbirimsel farklılıklardan bir tanesi de Türkmence'de olup da Türkçe'de olmayan eylem kipleridir. Örneğin Türkmence'de "***+makçy/+mekçi***" eki ile kişinin, ekin geldiği eylemi yapmayı düşündüğü veya niyetlendiği anlamı kurulur. Bunun Türkçe'de doğrudan karşılığı olmadığı için ÇSG üreten bir kural geliştirilmiştir:

```
define mAkCI "^DB+Noun+Inf1+A3sg+Pnon+Nom iste+Verb+Pos+Prog1+A3sg"
<- "+Think+Anon";
```

Bu gibi biçimbirimsel farklılıkları gidermek üzere toplam 24 kural kullanılmıştır.

7.1.4. İstatistiksel Dil Modeli Bileşeni

Aktarım sırasında ortaya çıkan biçimbirimsel ve sözcüksel belirsizliklerin giderilmesi için İDM'leri kullanan bu bileşenin görevi ve işleyiş tarzı, Bölüm 4.1'de açıklanmıştır. Bu amaçla, bitişken diller için Bölüm 4.3'te önerilen farklı türlerde İDM'ler üretilmiştir. İDM'lerin oluşturulması için yaygın olarak kullanılan iki farklı yardımcı araç bulunmaktadır: CMU-Cambridge Language Modeling Toolkit [65] ve SRILM [66]. Bu çalışmada kullanılan İDM'ler, En Büyük Olabilirlik Kestirimi yöntemi ile SRILM [66] kullanılarak oluşturulmuştur. Olasılıklar oluşturulurken yumuşatma için Good-Turing [28] yöntemi ile derece-düşürme modelleme [29] yöntemi beraber kullanılmıştır.

Uygulamada önerilen farklı İDM tiplerinin başarımları ayrı ayrı incelenmiş ve en başarılı sonuç üreten İDM belirlenmeye çalışılmıştır. Önerilen İDM tiplerinin başarım sonuçları Bölüm 8.3.4'te verilmiştir.

7.1.5. Türkçe Biçimbirimsel Sentezleyici

Türkçe için kullanılan biçimbirimsel çözümleyici [13] SDD yapısında tasarlanmış olduğu için ters yönde çalıştırıldığında biçimbirimsel üretici olarak görev görmektedir.

7.2. Aktarım Modeli 1 Gerçeklemesi

Model 1 kullanılarak gerçeklenen sistemin genel bileşenleri Şekil 7-6'de gösterilmiştir.

Model 0'ı temel alarak oluşturulan çeviri sisteminde çeviri işlemi, kaynak dildeki tümceyi oluşturan sözcüklerin, birbirlerinden bağımsız olarak aktarılması ile sağlanmaktadır. Ancak, sözcüklerin birbirlerinden bağımsız olarak değerlendirilmesi her koşulda uygun olmamaktadır. Bazı durumlarda, kaynak dildeki ÇSG'lerin bir bütün olarak aktarılması gereklidir. Bu çalışma düzenini sağlamak amacıyla, kaynak tümcedeki ÇSG'leri bularak bunları işaretleyen bir bileşen hazırlanmıştır. Böylelikle, kök aktarım bileşeni, bu yapıların bir bütün olduğunu anlayarak ona uygun aktarım işlemi gerçeklemektedir.

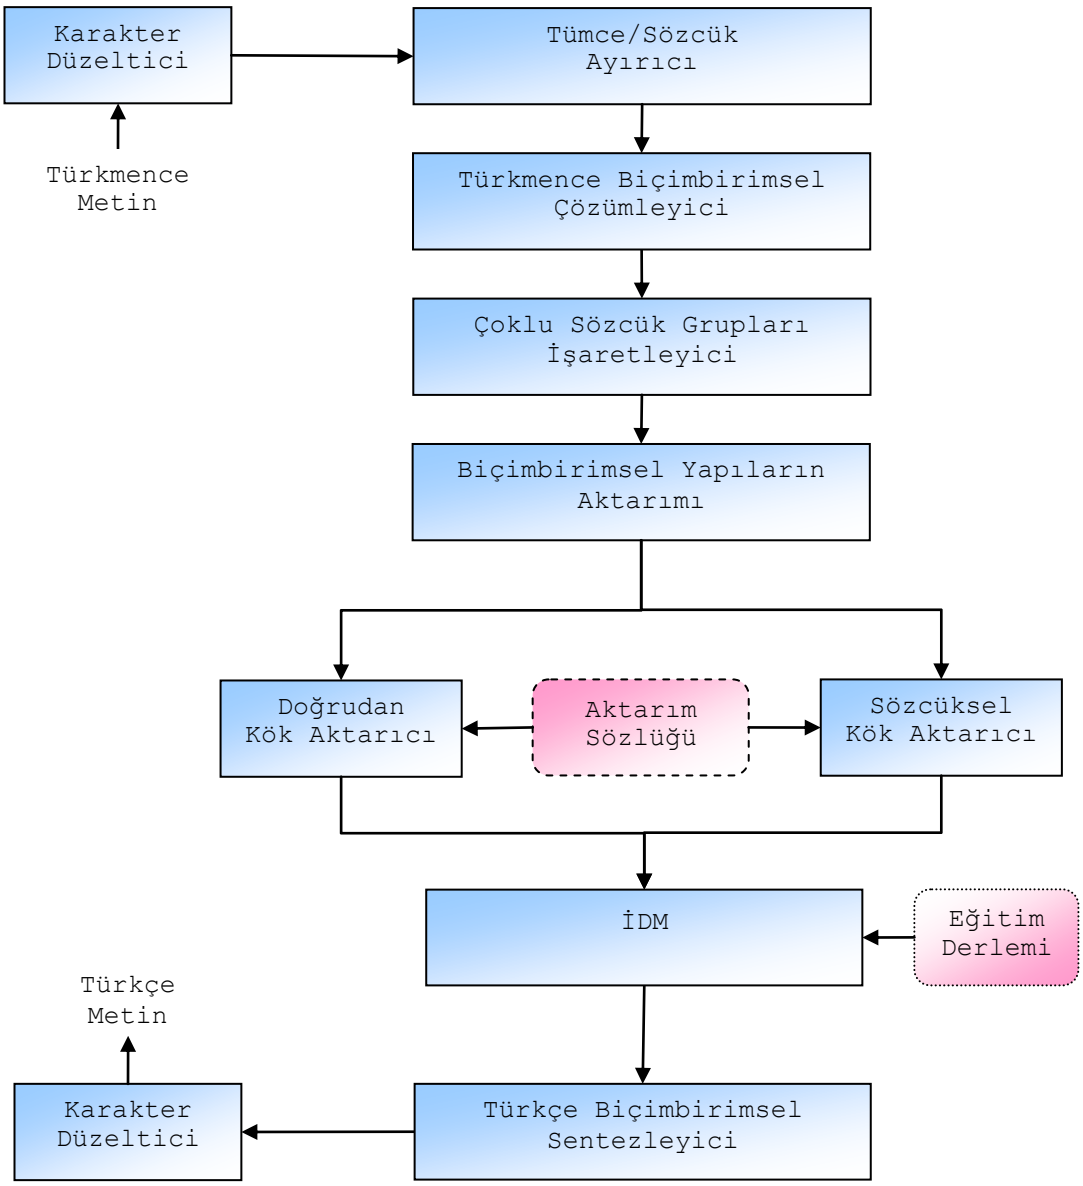

Şekil 7-6 : Aktarım Modeli 1 temelinde oluşturulan sistemin bileşenleri

Kaynak tümcedeki ÇSG'lerin belirlenmesi için, öncelikle Türkmence'de ÇSG'lerin nasıl oluştuklarının incelenmesi gereklidir. Bunun için Türkçe üzerine yapılmış olan bir çalışma baz alınarak Türkmence'ye uyarlanmıştır [45]. Bu çalışma uyarınca Türkçe'de dört tür ÇSG bulunmaktadır:

1. Sabit sözcüklerden oluşan gruplar
2. Kısmen sabit sözcüklerden oluşan gruplar
3. Sabit sözcük içermeyen kurallı gruplar
4. Yer, kişi vb. gibi özel isimleri ifade eden gruplar

Yukarıdaki sınıflandırma Türkmence için de uygun görülmektedir. Bu bağlamda Türkmence için de aynı sınıflandırma öngörülmüştür:

- Sabit sözcüklerden oluşan gruplar

Türkmence'de birden fazla sözcükten oluşan gruplar genellikle araya **"-"** işareti konularak yazılır:

Türkmence	Türkçe
dady-bidat	yazık
höre-köşe	güzel, tatlı (söz)
az-kem	hayal meyal
gürüm-jürüm	gizli

Ancak bu durumu garantilemek adına, bu şekilde birleşik yazılması gereken sözcüklerin bir listesi hazırlanmış ve bu listeye uygun olarak eksik **"-"** işaretleri varsa, bunu metnin ilgili yerlerine ekleyen bir araç geliştirilmiştir.

- Kısmen sabit sözcüklerden oluşan gruplar

Bu sınıftaki ÇSG'ler, biçimbirimsel açıdan türetme ve çekim olaylarından etkilenirler. Ancak genellikle ÇSG'nin içinde sadece son sözcük türetme ve/veya çekim eki alabilir. Bu da ÇSG'nin başındaki sözcüklerin sabit olduğu anlamına gelmektedir. Aşağıda bu duruma uyan örnekler verilmiştir:

Türkmence	Türkçe
gürüm-jürüm bolmak	kaybolmak
gürüm-jürüm etmek	saklamak
emele gelmek	ortaya çıkmak
ekin meýdanı	tarla

Yukarıda örnekleri verilen ÇSG'lerin sadece son sözcüğüne yapım ve çekim eki getirilebilir:

gürüm-jürüm bol**makçy**	(kaybolmayı düşünüyor)
gürüm-jürüm bol**ypdy**	(kaybolmuştu)
gürüm-jürüm et**jek**	(saklayacak)

Geliştirilen bir araç ile, biçimbirimsel çözümlemesi yapılmış sözcükler işlenerek, farklı yüzeysel biçimlere sahip bu ÇSG'ler aşağıdaki şekilde işaretlenmektedir:

```
…
gUrUm-jUrUm : gUrUm-jUrUm+Adverb
bolupdyr    : bol+Verb+Pos+Narr+Cop+A3sg
…
```

⇩

```
…
gUrUm-jUrUm_bolupdyr : gUrUm-jUrUm_bol+Verb+Pos+Narr+Cop+A3sg
…
```

Şekil 7-7 : Çekimlenen ÇSG'lerin bulunması

Bu şekilde işaretlenen ÇSG kökü aktarılırken, aktarım sözlüğünde ***gUrUm-jUrUm_bol*** eylemi aranmaktadır. Bu sayede ÇSG türetme ya da çekim eki alsa bile doğru olarak aktarılabilmektedir.

- Sabit sözcük içermeyen kurallı gruplar

Türkmence'de bazı ÇSG'ler, sabit sözcük içermeden, belirli kurallar çerçevesinde oluşturulur. Bu tür ÇSG'lere ilişkin birkaç örnek aşağıda verilmiştir:

Türkmence	Türkçe	Kurallı Yapı
geçip bildi	geçebildi	eylem_kökü+Hp bil+…
olup bilmez	olamaz	eylem_kökü+Hp bil+…
geljek däl	gelmeyecek	eylem_kökü+jAk däl+…
var eken	varmış	isim_kökü+… eken
öy be öy	evden eve	isim be isim

Bu tür ÇSG'lerde genellikle ekler sabit kalmakta, ama grup içerisinde sözcükler değişebilmektedir.

- Yer, kişi vb. gibi özel isimleri ifade eden gruplar

Bu sınıfta yer alan yapılar, Türkçe'ye olduğu gibi aktarılmaktadır, herhangi bir çeviri yapılmamaktadır.

Türkmence giriş tümcesindeki ÇSG'leri bulmak üzere hazırlanan bu araçlar birleştirilerek temel çeviri sistemine eklenmiştir.

7.3. Aktarım Modeli 2 Gerçeklemesi

Aktarım Modeli 1'e ek olarak tümce genelinde hem biçimbirimsel düzeyde hem de yüzeysel düzeyde çalışan kuralların eklenmesi ile gerçeklenen Aktarım Modeli 2'nin bileşenleri, Şekil 7-8'de gösterilmiştir:

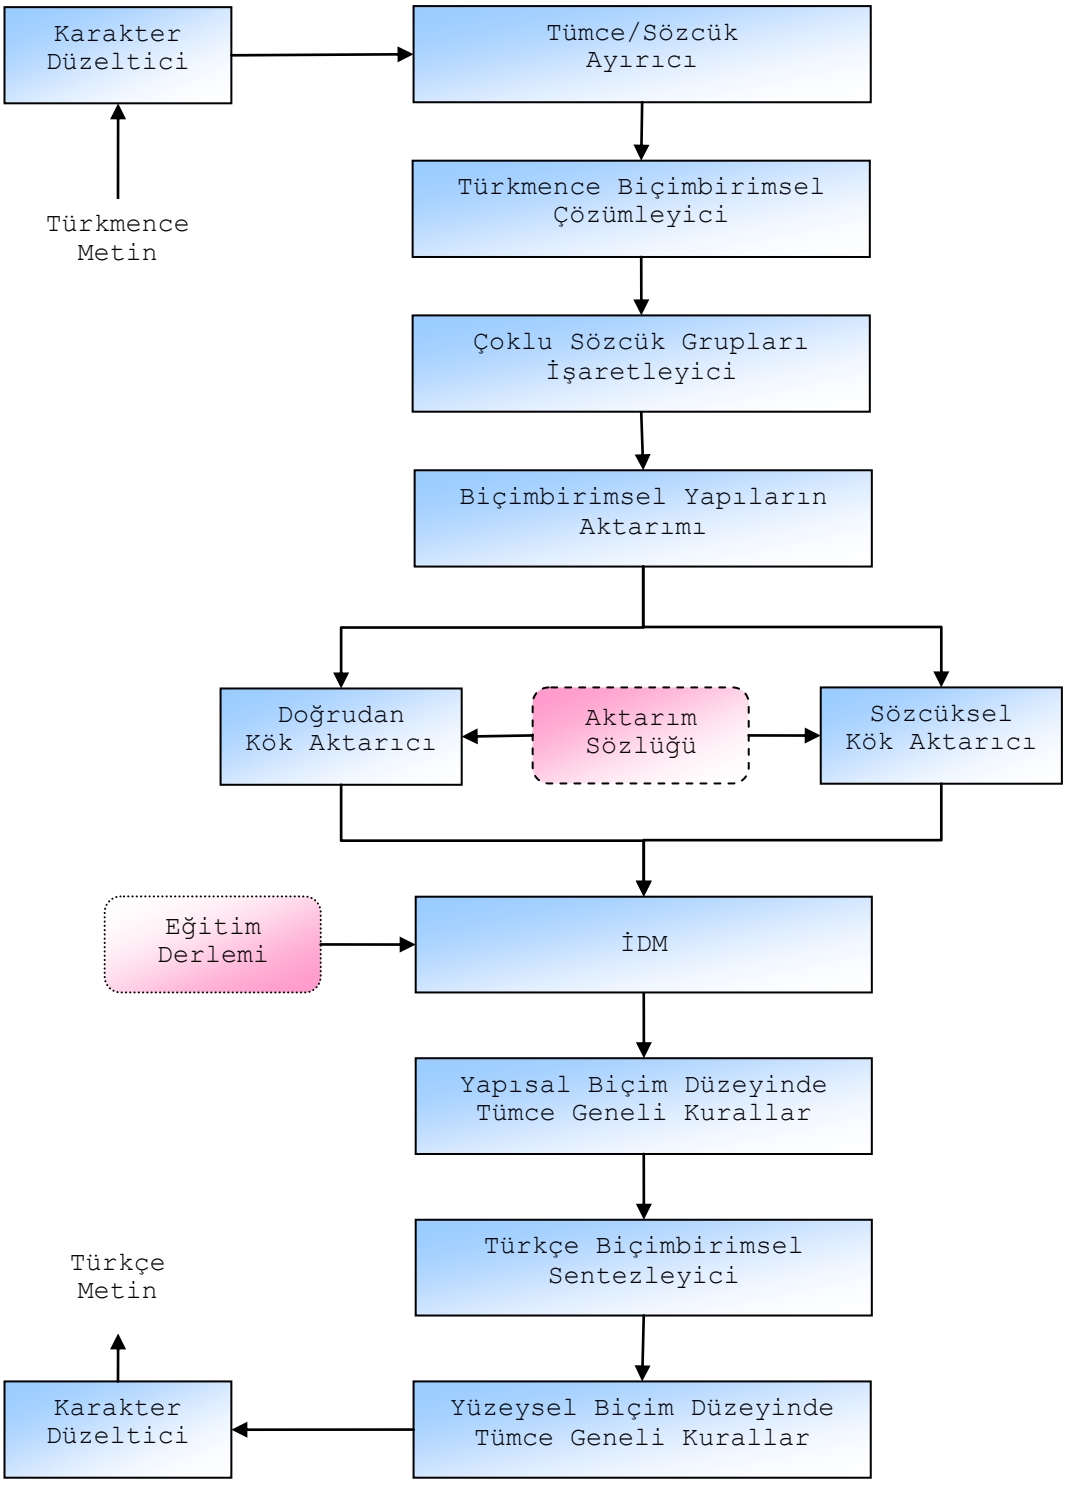

Şekil 7-8 : Aktarım Modeli 2 temelinde oluşturulan sistemin bileşenleri

Model 0'da sözcük bazında çeviri yapılmasından doğan bazı sıkıntılar Model 1'de ÇSG'lerin işlenmesi ile çözülmüştür. Ancak ÇSG'ler bulunurken sadece birbirlerine yakın sözcükler arasındaki ilişkiler dikkate alınmaktadır. Uygulamada, birbirlerine uzak sözcükler arasındaki bağımlılıklardan doğan çeviri hataları oluşmaktadır.

Sorunun çözümü için tümce bazında sözdizimsel çözümlemenin yapılmasına gerek olmasa da, tümce bazında yapılması gereken bazı işlemlerin olduğu sonucuna varılmıştır.

Örneğin Türkmence'de bazı kipler (gelecek zaman, zorunluluk ve planlama kipleri) şahıs eki almazlar[9], ancak Türkçe'de bu eylemleri yapan şahsın belirtilmesi zorunludur:

Türkmence	Türkçe
Men geljek	geleceğ+**im**
Sen geljek	gelecek+**sin**
O geljek	gelecek+Ø

Hedef dildeki tümcenin sözdizimsel çözümlemesinin olması durumunda özneye bakarak eyleme uygun şahıs bilgisini iliştirmek son derece basit bir işlemdir. Ancak daha önceki bölümlerde de nedenleri açıklandığı üzere, gerçeklenecek çeviri sisteminde sözdizimsel çözümlemeden kaçınılmaktadır. Aktarım başarımının yükseltilebilmesi için, sözdizimsel çözümleme yapılmasa dahi, tümce bazında bazı basit işlemlerin gerçeklenmesi gereklidir. Örnek olarak yukarıda anlatılan, eksik olan şahıs bilgisinin çıkarılması sorununun kısmen çözülmesi için tümcenin başında bazı adılların varlığı sorgulanabilir:

Men bu gije öýe geljek.
Ben bu gece eve geleceğim.

Sen bu gije öýe geljek.
Sen bu gece eve geleceksin.

Men ve Berdi bu gije öýe geljek.
Ben ve Berdi bu gece eve geleceğiz.

Berdi ve Seyid bu gije öýe geljek.
Berdi ve Seyid bu gece eve gelecekler.

Bu örneklerden de görüldüğü gibi, tümce başında bazı adıl kalıpları aranarak, eylemin eksik olan kişi bilgisi çıkarılabilir. Ancak bu kural, şahıs bilgisinin eksik olduğu tüm eylemler için çalışmayacaktır. Aşağıdaki karşı örnekte, tümce başında kişi zamiri olmadığı için doğru kişi bilgisi çıkarılamaz. Bu tür durumlarda eyleme ön tanımlı bir davranış olarak 3. tekil kişi etiketi (***+A3sg***) eklenir.

Bu gije **men** öýe geljek.

[9] Bu durum, biçimbirimsel çözümleyici tarafından ***+Anon*** etiketi ile temsil edilir.

Tümce genelinde yapılması gereken işlerden bir diğeri de Türkmence'deki ortaç öbeklerinde kendini göstermektedir. Türkçe'de ortaçların kendisine gelen iyelik eki, Türkmence'de ortacın nitelediği ismin sonuna gelmektedir:

Türkmence	Türkçe
berjek çöregi	vereceği ekmek
geljek yoluñyz	geleceğiniz yol
geljek owadan yoluñyz	geleceğiniz güzel yol
görmedik çölleriň	görmediğin çöller
gidýan yerimiz	gitmekte olduğumuz yer

Görüldüğü gibi, ortaçlarla kurulan ad öbekleri (noun phrase), sözdizimsel çözümleme kadar kesin olmasa da yaklaşık olarak kestirilmeli ve iyelik etiketinin yeri değiştirilmelidir.

Tümce bazında yürütülmesi gereken bir başka işlem de Türkçe'de ayrı yazılan ama kendinden önceki sözcüğün son seslisine göre değişen ***de / da*** bağlacı ile ***mi / mı / mü / mu*** soru ekleridir. Hedef dile çevrilen sözcükler yüzeysel biçime dönüştürüldükten sonra bazı kuralların tümce genelinde bu harf değişiklerini yapması gereklidir.

Yukarıda verilen üç örnek gibi, tümce genelinde iş yapan toplam sekiz farklı kural kümesi oluşturulmuştur. Bu kurallar, işlem yaptıkları düzeyler bakımından iki sınıfa ayrılırlar:

- **Yapısal Biçime Gerek Duyan Kurallar**

  Bu kuralların işlem görebilmesi için sözcüklerin biçimbirimsel verilerinin de bulunması gereklidir. Bundan dolayı bu kurallar, hedef dil biçimbirimsel üretici bileşeninden önce çalıştırılır.

- **Yüzeysel Biçim Üzerinde İşlem Yapan Kurallar**

  Genellikle sözcükler arası sesli uyumları ile ilgili harf değişikliklerini yapan bu kurallar ise hedef dil biçimbirimsel çözümleyiciden sonra üretilen sözcüklerin yüzeysel biçimleri üzerinde işlem yaparlar.

7.4. İki Seviyeli İDM Kullanılması

Farklı tipte İDM'lerin oluşturulmasının nedeni Bölüm 4.3'te anlatıldığı gibi seyrek veri sorunundan en az biçimde etkilenmektir. Bu nedenle tüm biçimbirimsel

etiketleri içeren tam çözümleme yerine, bu çözümlemelerin belirli bölümleri kullanılmıştır. Dolayısı ile her İDM, hedef dili, farklı açılardan modellemektedir. Örneğin İDM Tip-I kökleri modellerken İDM Tip-II sözcük türlerini modellemektedir.

Ancak belirli bir tip İDM seçildiğinde oluşan aday çeviriler, sadece seçilen İDM'nin modellediği açıdan değerlendirilmektedir. Örneğin kökleri modelleyen bir İDM, diğer biçimbirimsel bilgilerin hiçbirini değerlendirmeye katamaz. Bu olumsuzluğu gidermek adına, farklı tipte dil modellerinin beraber kullanılmasının yolları araştırılmıştır. Bu sayede hedef dili farklı açılardan modelleyen farklı tiplerdeki İDM'lerin sonuçları birleştirilerek en olası tümcenin bulunması denenmiştir.

Benzer sorunların çözümü için literatürde sıklıkla kullanılan bir yöntem, olasılığı en yüksek sıralamanın bulunması için iki farklı seviye kurulmasını öngörmektedir. "En İyi N Aday" (N-Best Lists) adı verilen bu yöntemde, 1. seviyede dar kapsamlı bir bilgi kaynağı ile tüm arama uzayında bir arama gerçeklenir ve çıktı olarak en olası N aday, olasılıklarına göre sıralanmış olarak 2. seviyeye aktarılır. Daha geniş kapsamlı bir bilgi kaynağı kullanan 2. seviye arama yöntem(ler)i, en iyi N adaydan oluşan daraltılmış arama uzayında işlem yaparak bu N adayı tekrar sıralar (re-ranking) ve sonuçta elde edilen en iyi adayı çıktı olarak üretir [67]. En İyi N Aday arama yöntemi kullanılırken, 1. aşama için kullanılan arama yönteminin maliyetinin düşük tutulmasına özen gösterilmesi gerekmektedir.

Çeviri sorununa geri dönersek, oluşturulan aday tümceler içerisinden bütün İDM Tipleri kullanılarak en olası tümceyi seçmenin maliyetinin çok yüksek olduğu görülmüştür.[10]. Bu noktada, En İyi N Aday yöntemini kullanabilmek amacıyla iki adet farklı İDM tipinin beraber kullanıldığı 2 seviyeli bir istatiksel modelleme gerçeklenmiştir. 1. seviyede kurulan HMM üzerinde çalışan geliştirilmiş Viterbi [68, 69] algoritması sayesinde olasılığı en yüksek bir tümce yerine N adet tümce üretilir. 2. seviyede ise arama uzayı küçültülen bu tümceler arasında (tercihen hedef dili daha geniş kapsamlı modelleyen) bir diğer İDM tipi ile 2. seviye tümce olasılığı hesaplanır. Son adımda ise her 1. ve 2. seviyelerde hesaplanan olasılık değerleri

[10] Standart bir bilgisayarda 255 tümcenin aktarımı yaklaşık 9 dakika sürmektedir.

birleştirilir ve tümcelerin son olasılık değeri bulunur. Bu sıralamada *N* tümce arasında en yüksek olasılığa sahip tümce çıktı olarak üretilir.

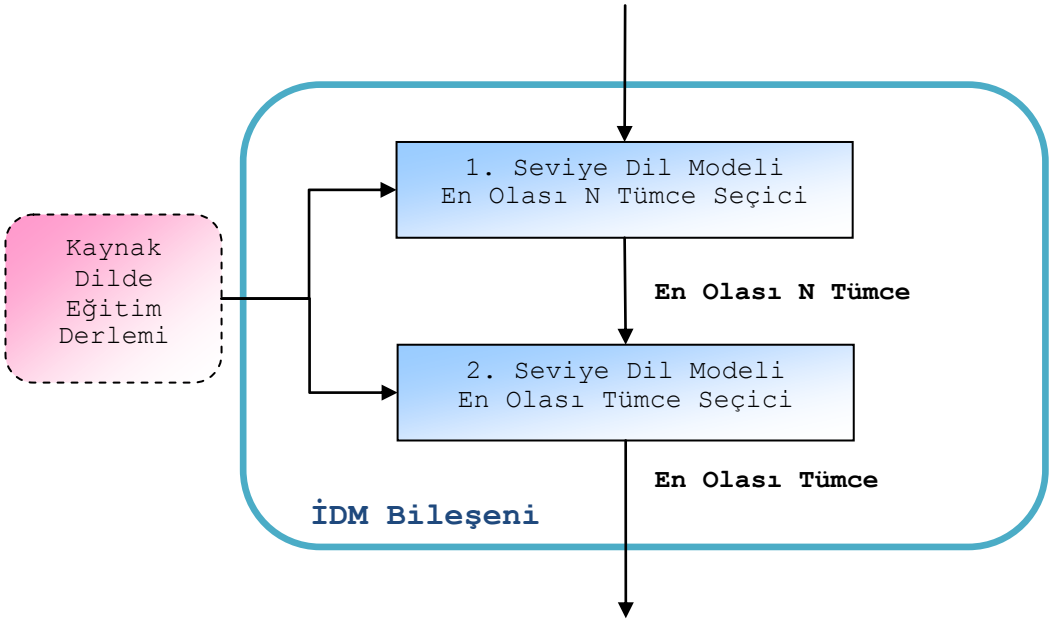

Şekil 7-9 : İki seviyeli İDM uygulaması

8. UYGULAMA VE SONUÇLAR

8.1. Eğitim ve Sınama Verisi

İDM'lerin eğitilmesi için bir eğitim derlemine gereksinim duyulmaktadır. Eğitim verisi olarak yaklaşık 1 milyon sözcükten ve 50 bin tümceden oluşan bir derlem kullanılmıştır. Derlemdeki tümceler, ağırlıklı olarak günlük bir gazetenin belirli bir dönemdeki haber metinlerinden oluşmaktadır. Derlem ile ilgili istatistiksel bazı bilgiler Tablo 8-1'de verilmiştir.

Tablo 8-1 : Eğitim derlemi ile istatistikler

Toplam Kelime Adedi	948.403
Toplam Tümce Adedi	50.674
Farklı Sözcük Kökleri Adedi	25.897
1 Defa Geçen Sözcük Kökleri	11.447
2 Defa Geçen Sözcük Kökleri	3505
2'den Fazla Geçen Sözcük Kökleri	10.945

Eğitim derlemi, sözcüklerin yüzeysel biçimlerini ve doğru biçimbirimsel çözümlemesini içermektedir. Derlemdeki sözcükler ilk önce Türkçe biçimbirimsel çözümleyiciden [13] geçirilmiş, ikinci aşamada da doğru biçimbirimsel çözümlemelerinin seçilmesi, kısmen elle kısmen de otomatik yöntemlerle gerçeklenmiştir. Bu derlem Türkçe üzerinde yapılan çeşitli biçimbirimsel belirsizlik giderme (morphological disambiguation) araştırmalarında kullanılmaktadır [51, 52, 70]. Eğitim verisinden alınan örnek bir tümce aşağıda verilmiştir:

```
<S> <S>+BSTag
İlköğretim ilköğretim+Noun+A3sg+Pnon+Nom
önce önce+Adverb
8 8+Num+Card
, ,+Punc
ardından ardından+Adverb
da da+Conj
mutlaka mutlaka+Adverb
11 11+Num+Card
yıla yıl+Noun+A3sg+Pnon+Dat
çıkarılmalıdır çık+Verb^DB+Verb+Caus^DB+Verb+Pass+Pos+Neces+Cop+A3sg
</S> </S>+ESTag
```

Ayrıca Türkmence ile Türkçe arasındaki farklılıklardan dolayı derlem üzerinde uyumlaştırıcı bazı yapay değişiklikler yapılmıştır:

1. Türkmence'de, sözcüğe bitişik yazılan ***+ylA*** aracılık durum eki olmadığı için, Türkçe eğitim derleminde ***+Ins*** durumunda olan tüm isim soylu sözcükler yalın hale (***+Nom***) getirilmiş ve bu sözcükten hemen sonra ***ile+Postp+PCNom*** eklenmiştir (arabayla ⇨ araba ile).
2. Soru eki Türkmence'de eyleme bitişik yazılmaktadır. Ancak Türkçe'de ayrı yazılan ve derlemde ***+mı, +mu, +mi, +mü*** şeklinde geçen farklı soru kökleri bulunmaktadır. Eğitim derleminde bu girdiler silinmiş, bunlardan önceki eylemin sonuna ***+Ques*** takısı eklenmiştir.

Sisteminin başarısının sınanabilmesi için bir sınama kümesi oluşturulmuştur. Bu sınama kümesi, ağırlıkla hikayelerden alınmış 255 adet Türkmence tümce ve bu tümcelerin 2 farklı kaynaktan sağlanmış Türkçe karşılıklarını (referans çevirilerini) içermektedir.

Çeviri sırasında biçimbirimsel ve sözcüksel belirsizlikler oluşmaktadır. Bu belirsizliklerin derecesini göstermek amacıyla, sınama kümesi çevrilirken çıkan belirsizlik oranları, Tablo 8-2'de verilmiştir.

Tablo 8-2 : Sınama kümesinde ölçülen belirsizlik oranları

Türkmence'de Sözcük Başına Düşen Biçimbirimsel Çözümleme Adedi	1,55
Türkçe Karşılığı 1 Tane Olan Türkmence Sözcük Oranı	% 44,7
Türkçe Karşılığı 2 Tane Olan Türkmence Sözcük Oranı	% 34,0
Türkçe Karşılığı > 2 Olan Türkmence Sözcük Oranı	% 21,3

8.2. Değerlendirme Ölçütleri

Önerilen çeviri modellerinin ve İDM türlerinin başarımlarını ölçmek için *BLEU* ölçütü seçilmiştir. Ancak *BLEU* ölçütünün, Türk dilleri için bazı olumsuz yönleri bulunmaktadır.

Türkçe, tümcedeki öğelerin (belirli bir derecede) yer değiştirebildiği (free constituent order) bir dildir. Burada kullanılan öğe tanımı, sözcük öbekleri anlamındadır. Çoğu Türkçe tümce özne-nesne-yüklem sırasını izlemesine rağmen özellikle konuşma

dilinde farklı sıralar izlenebilir. Birçok dilde sözcüklerin tümce içindeki görevleri tümce içerisindeki yerlerine yani sıralarına göre belirlenirken, Türkçe'de sözcük öbeklerindeki biçimbirimsel yapılar, tümcedeki yerinden bağımsız olarak öbeğin görevini gösterir. Sözcük öbeklerinin farklı sıralamaları ise farklı bağlamlarda farklı noktaları vurgular [71].

BLEU yönteminde, birden fazla referans çeviri kullanılarak sistemin çıktısı ile bu referanslar arasındaki sözcük dizilerinin (genellikle 4 uzunluğa kadar) eşleşme oranlarına bakılır. Dolayısı ile çeviri sistemi, tümcedeki öğeleri referanslardan farklı şekilde sıralamışsa, söz konusu sistem çıktısı *BLEU* tarafından çok düşük puanlandırılır.

Ancak Türkçe'de öğelerin sırası değişse bile tümcenin anlamı aynı kalabildiği için sistem çıktısının, referans(lar)la aynı anlamı taşıyan tümceler üretme olasılığı da bulunmaktadır:

```
Referans          : Kedi    evdeki vazoyu  kazayla kırdı.
Sistem Çıktısı 1 : Evdeki  vazoyu kazayla kedi    kırdı. BLEU = 0,55
Sistem Çıktısı 2 : Kazayla evdeki vazoyu  kırdı   kedi.  BLEU = 0,38
Sistem Çıktısı 3 : Kırdı   vazoyu kazayla evdeki  kedi.  BLEU = 0,38
```

Örnekler incelendiğinde, 3. çıktı, çok daha bozuk bir Türkçe tümce olmasına karşın, 1. sistemin çıktısı ile arasında aynı oranda puan farkı yoktur. Oysa ki 1. sistem çıktısı, referans ile aynı anlamı taşımaktadır ve sadece referanstaki "***kazayla"*** sözcüğünde yer alan vurguyu "***kedi***" sözcüğüne aktarmıştır. Örnek sistem çıktısı 2, sistem çıktısı 3'den çok daha doğru bir Türkçe tümce olmasına rağmen çıktı 3 ile aynı puanı almıştır. Bu örneklerden görüldüğü gibi *BLEU* ölçütü, Türkçe sistemlerin başarımını tam anlamı ile ölçememektedir.

Ancak öngörülen aktarım modelleri sözcük sıralarında büyük bir değişikliğe gitmediği için, yukarıda açıklanan sakıncaların etkisi çok daha az olacaktır.

BLEU ölçütünün bitişken diller açısından bir başka olumsuz yönü ise, referans ile aday çeviriler arasında eşleme yaparken sözcüklerin sadece yüzeysel biçimlerinin işlenmesidir. Aktarım sistemi, biçimbirimsel özelliklerden bir tanesinde bile hata yaparsa, oluşan sözcüğün yüzeysel biçimi farklı olmakta ve *BLEU* puanı çok düşük olmaktadır:

```
Referans       : Kedi evdeki vazoyu kazayla kırmış.
Sistem Çıktısı : Kedi evdeki vazoyu kazayla kırmıştır.   BLEU = 0,66
```

Örnekte, aktarım sisteminin, biçimbirimsel yapıların aktarımı sırasında seçtiği, ancak çok büyük anlam kaymasına yol açmayan bir farklılığın, *BLEU* puanını nasıl önemli ölçüde düşürdüğü görülmektedir. Bu olumsuz etkiyi azaltmak için, sistemin başarımı ölçülürken, sadece köklerin eşleşmelerinden hesaplanan *BLEUr* puanı ile normal *BLEU* puanı beraber kullanılmıştır. *BLEUr* puanını hesaplamak amacıyla, referans çeviriler kümesindeki sözcüklerin biçimbirimsel çözümlemesi yapılmış ve sözcük kökleri elle seçilerek kök referans kümesi de oluşturulmuştur.

Sonuç olarak *BLEU* ölçütü, Türk dil ailesindeki dillerin hedef dil olduğu bilgisayarlı çeviri sistemlerinin başarım değerlendirmesi için en uygun yöntem değildir. Ancak otomatik olması, yaygın olarak kullanılması ve alternatifinin olmaması gibi nedenler göz önüne alındığında uygulamamızın başarım değerlendirmesi *BLEU* yöntemi ile yapılmıştır. Ancak *BLEU* ölçütü, gerçeklenen çeviri sisteminin başka sistemlerle karşılaştırılması amacı yerine daha çok sisteme eklenen bileşenlerin ve yeni kuralların etkilerini saptamak amacı ile kullanılmaktadır [42]. İDM kullanılırken, bağlamı belirlediği için noktalama işaretleri kullanılmış olsa da *BLEU* puanları hesaplanırken noktalama işaretleri gözardı edilmiştir.[11]

Önerilen modellerin sözcük sıralarında neredeyse hiçbir değişiklik yapmadığı dikkate alındığında, sıradan bağımsız olarak tek sözcük eşleşmelerinin de (1 uzunluklu eşleşmeler) başarım hakkında bir ipucu verebileceği akla gelmektedir. *BLEU-1* puanı olarak gösterilen bu tekli eşleşmeler, sistemin referanstaki sözcükleri sıradan bağımsız olarak üretebilme yeteneğini gösterir. Bu nedenle, sonuçlar verilirken BLEU-1 puanları da belirtilmiştir. Sözcük sıralarında herhangi bir değişiklik yapılmadığı varsayımı ile sistemin ulaşabileceği başarımın üst sınırı, en yüksek *BLEU-1* puanı olan 100 almaktır. Ancak *BLEU-1* puanı olarak 100 elde edilmesi, genel *BLEU* puanının da yüksek olmasını gerektirmediği unutulmamalıdır. Örneğin referanstaki sözcüklerin dağınık bir şekilde birleştirilmesiyle oluşan bir çeviri çıktısı, tekli eşleşmelerden (*BLEU-1*) 100 puan alsa bile ikili (*BLEU-2*), üçlü (*BLEU-3)* ve dörtlü (*BLEU-4*) eşleşmelerden puan alamayağı için, çıktının genel *BLEU* puanı çok daha düşük olacaktır.

---

[11] BLEU puanı hesaplaması için kullanılan araç, 2005 yılında düzenlenen istatistiksel çeviri yarışmasının değerlendirme aracıdır: http://www.statmt.org/wmt05/shared-task/ (2005) Bu aracın çıktılarında, normalde 0-1 aralığında olan BLEU puanı 0-100 arasına çekilerek verilmektedir.

8.3. Sonuçlar

Tasarlanan aktarım fonksiyonu modellerinin başarımlarını incelemek için her bir modelin sınama girdisine karşılık ürettiği çevirilerin *BLEU* ve *BLEUr* puanları hesaplanmıştır. İlk önce temel model puanı hesaplanmış ve bu bir alt sınır olarak kabul edilmiştir. Daha sonra diğer modellerin *BLEU* ve *BLEUr* puanları ile temel sistemin başarımı karşılaştırılmıştır.

8.3.1. Temel Modelin Başarımı

Geliştirilen temel aktarım modeli, 1-gram kök İDM (Tip-I) ile çalıştırılmış ve başarımı ölçülmüştür:

Tablo 8-3 : Aktarım Modeli 0'ın (Temel Model) Başarımı

Aktarım Modeli	***BLEU***	***BLEU-1***	***BLEUr***	***BLEUr-1***
Model 0	26,57	58,80	35,58	68,40

Bu tabloda *BLEU*-1 ve *BLEUr*-1 puanları, sırasıyla yüzeysel biçimde ve kök biçiminde referanslarla eşleşen sözcük yüzdelerini (1-gram eşleşmelerini) vermektedir. Buna göre Model 0 (temel model), referanslarda geçen sözcüklerin %58,80'lik bir oranını doğru olarak üretebilmeyi başarmış, üstelik sözcük köklerinin %68,40'ını doğru seçmiştir. Ancak hatalı çeviriler yüzünden 2-gram, 3-gram ve 4-gram eşleşmelerinin sayıları azalmış ve sonuçta daha düşük *BLEU* puanları alınmıştır.

BLEU ile *BLEUr* arasındaki farklar ise, sözcüksel belirsizliğin doğru olarak giderilebildiği ancak biçimbirimsel belirsizliğin giderilmesinde yanlışlık yapıldığı durumlardan kaynaklanmaktadır. Başka bir deyişle bu fark, doğru sözcük kökü seçilmesine rağmen, Türkmence biçimbirimsel belirsizlik doğru giderilemediği veya için yanlış bir yüzeysel biçimin oluşturulduğu örneklerden kaynaklanmaktadır.

Bu başarımlar, sistem üzerinde yapılacak her türlü değişikliğin sonuçlarını ölçmemize yarayan bir temel kıyaslama (baseline) sonucu olacaktır. Yapılan her türlü değişiklik sonucu elde edilen başarımlar, bu temel kıyaslama sonucuyla göreceli olarak değerlendirilmelidir. Bu puanlardan düşük sonuçlar, sistem üzerinde iyileştirme amaçlı yapılan değişikliklerin olumsuz sonuç verdiğini göstermektedir.

8.3.2. Aktarım Modeli 1'in Başarımı

Temel modele ek olarak ÇSG'lerin de çevrilmesi sağlanarak sözcük bazında çoktan-çoğa çeviri yapılmasını gerçekleyen Aktarım Modeli 1, gene köklerden oluşan Tip-I İDM ile *n=1* seçilerek çalıştırılmış ve aşağıdaki sonuçlar elde edilmiştir:

Tablo 8-4 : Aktarım Modeli 1 başarımı

Aktarım Modeli	***BLEU***	***BLEU-1***	***BLEUr***	***BLEUr-1***
Model 0	26,57	58,80	35,58	68,40
Model 1	28,45	60,90	38,03	70,20

Tablo 8-4'den görüldüğü gibi ÇSG'lerin işlenerek aktarılması, *BLEU* puanlarını yükseltmektedir. Örneğin, temel sistem tarafından doğru aktarılamayan sınama derlemindeki aşağıdaki yapılar, ÇSG'lerin belirlenerek hedef dile aktarılması sayesinde doğru olarak çevrilebilmiştir:

ulanylyp başlaýar	➔	kullanılıp başlıyor	(Model 0)
		kullanılmaya başlıyor	(Model 1)
durup bilmeýip	➔	durup bilmeyip	(Model 0)
		duramayıp	(Model 1)
gürüm-jürüm bolypdyr	➔	gizli olmuştur	(Model 0)
		kaybolmuştur	(Model 1)

8.3.3. Aktarım Modeli 2'in Başarımı

Tümce genelinde yapısal ve yüzeysel düzeylerde çalışan kuralların Model 1'e eklenmesiyle geliştirilen Model 2'nin başarımı aşağıda verilmiştir. Diğer aktarım modellerinin başarımları ile adil bir şekilde karşılaştırma yapılabilmesi için aktarım modeli 2 için de köklerden oluşan Tip-I İDM *n=1* seçilerek çalıştırılmıştır.

Tablo 8-5 : Aktarım Modeli 2'nin başarımı

Aktarım Modeli	***BLEU***	***BLEU-1***	***BLEUr***	***BLEUr-1***
Model 0	26,57	58,80	35,58	68,40
Model 1	28,45	60,90	38,03	70,20
Model 2	30,53	62,30	37,81	70,60

Tümce genelinde gerçeklenen aktarım kuralları ile Model 2'de başarımın arttığı görülmektedir. Aşağıdaki örnekler, tümce seviyesinde çalışan kurallar ile düzeltilen bazı durumları göstermektedir:

```
günleriñ birinde bir owadanja guş bar eken.                (Türkmence)
günlerin birinde bir güzelce kuş var imiş.                 (Model 1)
günlerin birinde bir güzelce kuş varmış.                   (Model 2)

olar günüñ  öñki duran ÿerine jemlenişmege başladylar.     (Türkmence)
onlar günün önceki duran yerine toplaşmaya başladılar.     (Model 1)
onlar günün önceki durduğu yere toplaşmaya başladılar.     (Model 2)

men hem suwuñ içinde gezip ÿadadym.                        (Türkmence)
ben da suyun içinde bulunup yoruldum.                      (Model 1)
ben de suyun içinde bulunup yoruldum.                      (Model 2)
```

8.3.4. Farklı Türde Dil Modellerinin Başarımı

Aktarım fonksiyonunun ürettiği tümcelerden en yüksek olasılığa sahip olanını bulmak için değişik İDM tipleri kullanılmış ve üretilen çevirilerin *BLEU* puanları hesaplanmıştır. İDM derecesinin etkisinin de görülebilmesi amacı ile *n=1,3* ve *5* seçilerek deneyler tekrarlanmıştır.

Tablo 8-6 : İDM Tip-I başarımı

Aktarım Modeli	***BLEU***			***BLEU-1***		
	n=1	***n=3***	***n=5***	***n=1***	***n=3***	***n=5***
Model 0	26,57	27.60	27.88	58,80	59.3	59.4
Model 1	28,45	29,47	29,75	60,90	61,40	61,50
Model 2	30,53	31,03	31,30	62,30	62,60	62,70
	BLEUr			***BLEUr-1***		
Model 0	35,58	35,52	35,67	68,40	68,90	69,00
Model 1	38,03	37,98	38,14	70,20	70,90	70,90
Model 2	37,81	37,77	37,92	70,60	71,30	71,30

Tablo 8-6'da göze çarpan en önemli nokta, beklendiği üzere dil modeli derecesi *n*'nin artması ile çeviri başarımının yükselmesidir. Ancak *n=3* ve *n=5* arasında çok büyük bir fark bulunmamaktadır. Gerçekten de söz konusu dil modellerinin derecelerine göre entropi değişimlerine bakıldığında (Tablo 4-8), *n>3* için entropi değerinin çok fazla değişmediği görülmektedir. Uygulama açısından *n=5* için

çalışma süresi çok yüksek olduğundan önerilen aktarım modeli için *n=3* seçilmesi uygun görülmektedir [12].

Daha önce de gözlendiği gibi, Tablo 8-6 ile aktarım modelleri başarımları karşılaştırıldığında Model 2'nin başarısının diğerlerinden yüksek olduğu görülmektedir.

Yapısal gösterimdeki son sözcük türlerinden oluşan İDM Tip-II'nin başarım değerledirme sonuçlarını içeren tablo aşağıda verilmiştir:

Tablo 8-7 : İDM Tip-II başarımı

Aktarım Modeli	***BLEU***			***BLEU-1***		
	n=1	***n=3***	***n=5***	***n=1***	***n=3***	***n=5***
Model 0	22,79	22,49	22,63	54,30	54,30	54,50
Model 1	24,48	24,15	24,35	56,40	56,30	56,70
Model 2	24,95	24,73	24,89	56,40	56,70	56,80
	BLEUr			***BLEUr-1***		
Model 0	26,24	26,49	26,57	61,10	61,40	61,50
Model 1	28,19	28,30	28,50	62,70	62,90	63,10
Model 2	28,10	28,13	28,16	62,80	63,20	63,30

İDM olarak Tip-II kullanıldığında elde edilen sonuçlarda gözlenen başlıca farklılık, dil modeli derecesinin artması ile başarının fazla değişmemesidir. Bu durum, önerdiğimiz çeviri yönteminde, sözcük türlerinden oluşan bir İDM bileşenin tek başına yeterli olmadığının bir göstergesi olarak yorumlanabilir. Ayrıca İDM Tip-II ile elde edilen puanların tamamı, temel sistemin puanından geride kalmaktadır.

Tablo 8-8'de, biçimbirimsel çözümlemelerin son ÇG'lerinden oluşturulan İDM Tip-III'ün *BLEU* sonuçları verilmiştir.

[12] Ses tanıma, istatistiksel çeviri gibi bir çok günümüz uygulamalarında genellikle İDM için n=3 seçilmektedir.

Tablo 8-8 : İDM Tip-III başarımı

Aktarım Modeli	***BLEU***			***BLEU-1***		
	n=1	***n=3***		***n=1***	***n=3***	
Model 0	23,17	23,88	23,99	55,00	55,90	56,00
Model 1	24,92	25,63	25,66	57,30	58,20	58,10
Model 2	25,25	26,39	26,41	57,30	58,80	58,60
		BLEUr			***BLEUr-1***	
Model 0	28,00	28,19	28,13	62,20	62,60	62,70
Model 1	30,10	30,30	30,24	64,00	34,40	64,50
Model 2	29,74	30,05	30,08	64,10	64,70	64,70

Çözümlemelerin son ÇG'leri kullanılarak oluşturulan Tip-III İDM, sözcük kökleri içeren Tip-II İDM'ye göre bir miktar daha fazla biçimbirimsel bilgiyi kullanmaktadır. Bu nedenle Tip-II *BLEU* puanlarına göre ufak bir artış gözlenmiştir. Ayrıca Tip-II'nin tersine, dil modeli derecesi arttıkça başarımlarda küçük artışlar sağlanabilmektedir. Ancak gene de temel sistemin başarısına çoğu durumda ulaşılamamış, ancak Model 2 kullanıldığında *n=3* ve *5* için temel sistem başarımına yakınsanmıştır.

Tip-I ve Tip-II İDM'nin birleştirilmesi ile oluşan kök ve sözcük türü bilgilerini kullanan Tip-IV İDM'nin başarım tablosu aşağıda verilmiştir.

Tablo 8-9 : İDM Tip-IV başarımı

Aktarım Modeli	***BLEU***			***BLEU-1***		
	n=1	***n=3***	***n=5***	***n=1***	***n=3***	***n=5***
Model 0	26,31	29,52	29,52	57,90	60,40	60,40
Model 1	28,20	31,37	31,37	60,10	62,60	62,60
Model 2	29,69	33,34	33,34	61,30	64,00	64,00
		BLEUr			***BLEUr-1***	
Model 0	34,30	35,51	36,51	67,20	69,00	69,00
Model 1	36,66	38,84	38,84	69,10	70,80	70,80

Model 2	36,44	38,62	38,62	69,40	71,20	71,20

Kök bilgisinin eklenmesi ile *n=1* için temel sistem başarısı yakalanmış, *n=3* ve *n=5* dereceleri için ise temel sistem başarımı geçilebilmiştir. Tip-IV İDM ile Tip-I İDM karşılaştırılacak olursa, *BLEUr* puanlarında bir değişilik olmamasına karşın son sözcük türü gibi biçimbirimsel bir bilginin eklenmesi ile toplamda bir başarı artışının sağlandığı söylenebilir.

Sözcük kökleri ile çözümlemelerin son ÇG'sinden oluşan Tip-V İDM kullanılarak yapılan sınamaların sonuçları Tablo 8-10'da verilmiştir. Sonuçlar incelenmeden önce sezgisel olarak şu sav ileri sürülebilir : "*eğer sözcük kökü bilgisine sözcük türü gibi biçimbirimsel bir bilgi eklenerek oluşturulan İDM ile başarı yükseltilebiliyorsa, sözcük köküne daha fazla biçimbirimsel bilgi eklenerek başarım daha da arttırılabilir*". Ancak Tablo 8-10 incelendiğinde sonuçların hiç de beklendiği gibi çıkmadığı görülebilir. Genel *BLEU* puanının düşmesinin temel nedeni, *BLEUr-1* değerlerinin düşmesine bağlıdır. Yani sistem sözcük köklerini aktarırken bu İDM ile daha fazla hata yapmaktadır. Bu sonuç, İDM Tip-V'in seyrek veri sorunundan fazlaca etkilendiğini ve bu yüzden sözcük kökü aktarımındaki başarının düştüğünü göstermektedir.

Tablo 8-10 : İDM Tip-V başarımı

Aktarım Modeli	***BLEU***			***BLEU-1***		
	N=1	***n=3***	***n=5***	***n=1***	***n=3***	***n=5***
Model 0	27,80	27,71	27,71	59,40	59,10	59,10
Model 1	29,80	29,71	29,71	61,60	61,40	61,40
Model 2	31,69	31,51	31,51	62,60	62,70	62,70
	BLEUr			***BLEUr-1***		
Model 0	33,29	32,39	32,39	67,10	66,70	66,70
Model 1	35,58	34,66	34,66	68,90	68,40	68,40
Model 2	35,59	34,46	34,46	69,10	68,80	68,80

Kök bilgilerini içermeyen, sadece biçimbirimsel çözümlemenin kök harici bileşenlerini içeren İDM Tip-VI ile elde edilen çevirilerin *BLEU* puanları Tablo 8-11'de verilmiştir.

Tablo 8-11 : İDM Tip-VI başarımı

Aktarım Modeli	***BLEU***			***BLEU-1***		
	N=1	***n=3***	***n=5***	***n=1***	***n=3***	***n=5***
Model 0	23,40	24,40	24,80	55,20	56,40	56,60
Model 1	25,15	25,91	26,47	57,40	58,60	58,80
Model 2	25,47	27,02	27,46	57,50	59,20	59,30
		BLEUr			*BLEUr-1*	
Model 0	29,50	29,85	29,93	62,90	63,30	63,40
Model 1	31,58	31,93	32,01	64,70	65,10	65,20
Model 2	31,24	31,60	31,74	64,80	65,50	65,50

İDM Tip-VI'nın başarım tablosu incelendiğinde bütün durumlarda temel sistemin başarımının altında bir sonuç elde edildiği görülmektedir. Kuşkusuz bunda en önemli etken, kök bilgisi içermeyen bu İDM ile köklerin aktarımında hatalar yapılmasıdır. Bu durum, *BLEUr-1* puanları incelendiğinde açıkça gözlenmektedir.

Modeller arasında farklı dil modeli tiplerinin kullanılmasının incelenmesi amacı ile de aşağıdaki çizelgeler oluşturulmuştur. Sınanan dil modeli tiplerinin, Model 0 ile birlikte kullanıldığı çevirilerde ölçülen *BLEU* puanları Şekil 8-1'de verilmiştir:

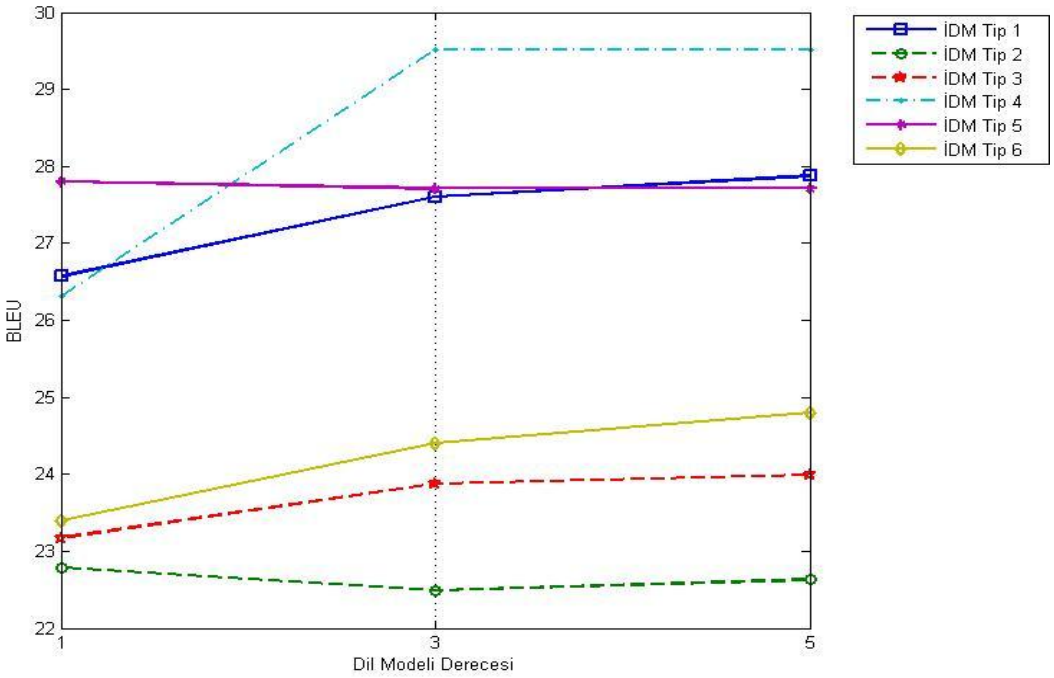

Şekil 8-1 : Aktarım Modeli 0'ın farklı İDM tipleri ile başarım grafiği

Çizelgeden de görülebileceği gibi, en başarısız İDM tipi, sözcük türlerinden oluşan Tip-II olurken en başarılı *BLEU* puanları kök ve son ÇG üzerinde üretilen Tip-IV olmuştur. Gözlenen bir başka sonuç ise kök kullanmayan İDM tipleri ile yapılan deneylerde (Tip-II ve Tip-III) *BLEU* sonuçlarının diğerlerine göre düşük çıkmasıdır. Bunun nedeni, sadece sözcük türünün ya da son ÇG'nin, çeviri sırasında ortaya çıkan belirsizlikleri çözmek için yeterli bilgiye sahip olmaması olarak gösterilebilir. Nitekim bu modellere kök bilgisi eklendiğinde (Tip-IV ve Tip-V) başarım gözle görülür bir şekilde yükselmektedir.

Şekil 8-2 ve Şekil 8-3'de, aktarım modeli 1 ve aktarım modeli 2 için farklı türlerdeki İDM'lerin başarımları çizelge olarak verilmiştir. Her iki çizelge incelendiğin, Şekil 8-1'deki çizelge ile aynı yapıda oldukları gözlenmektedir. Model 1 çizelgesi Model 0'a göre, Model 2 çizelgesi de Model 1'e göre yukarı ötelenmiştir. Bu da modellerin başarımları arasındaki farklardan kaynaklanmaktadır. Ancak İDM türlerinin başarımları arasındaki sıralama, bütün çizelgelerde aynı kalmaktadır.

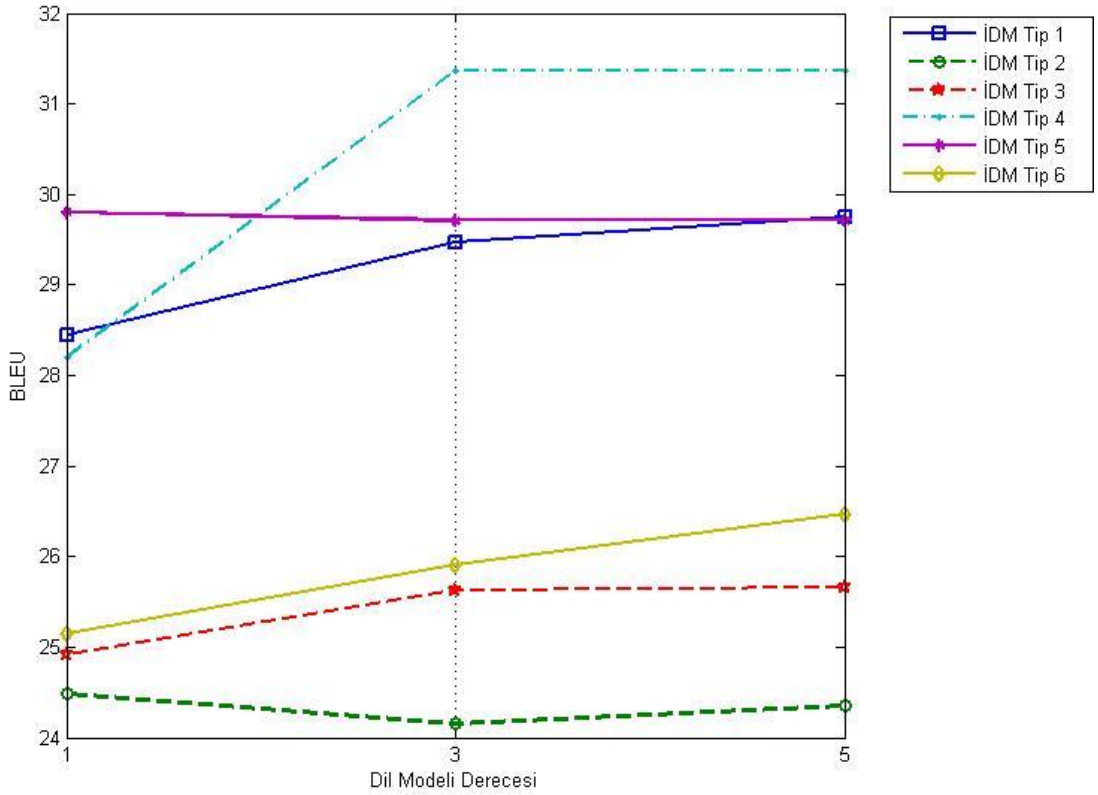

Şekil 8-2 : Aktarım Modeli 1'in farklı İDM tipleri ile başarım grafiği

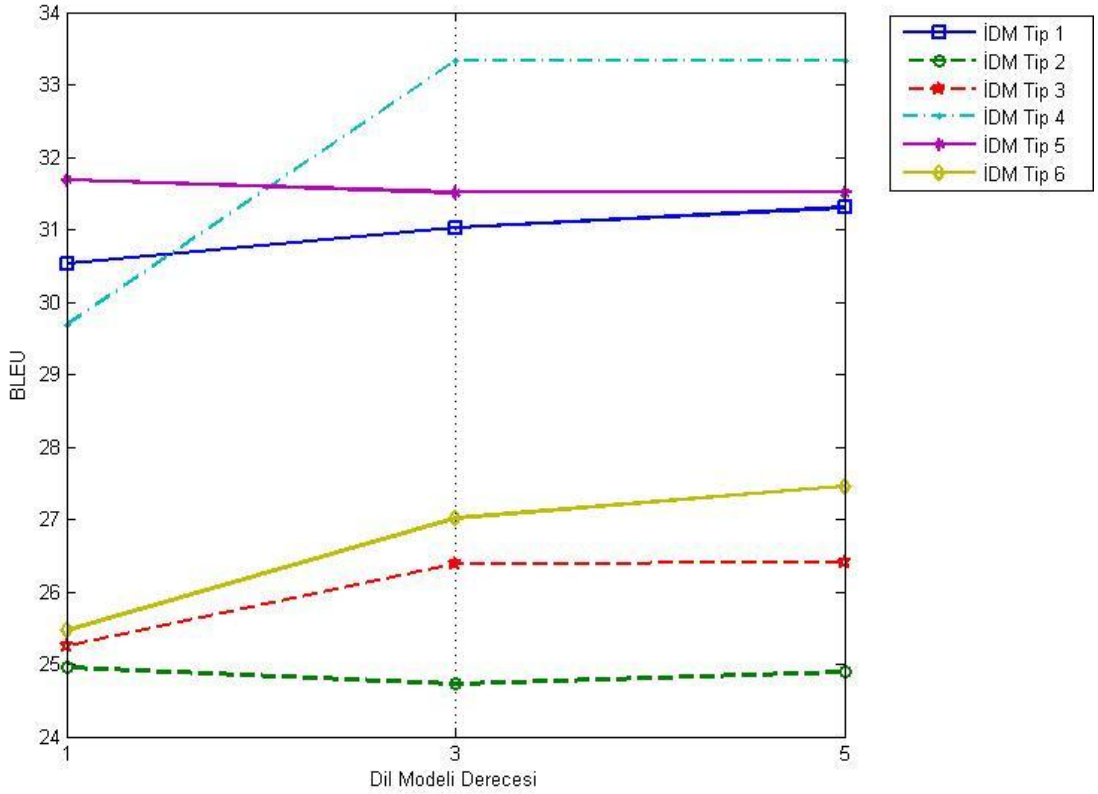

Şekil 8-3 : Aktarım Modeli 2'nin farklı İDM tipleri ile başarım grafiği

Şimdiye kadar sunulan veriler ışığında, sonuçlar aşağıdaki gibi özetlenebilir:

1. Hangi dil modeli türü kullanılırsa kullanısın, modeller arasında aşağıdaki sıralama (bir ya da iki durum dışında) değişmemiştir:

   $BLEU_{Model\text{-}2} > BLEU_{Model\text{-}1} > BLEU_{Model\text{-}0}$

2. Sonuçlar, dil modeli derecesinin seçilmesi açısından değerlendirildiğinde, 5. dereceden İDM'lerin en başarılı sonuçları ürettikleri görülmüştür. Ancak 3. derece İDM'lerin başarımları, 5. derece İDM'lerden çok düşük olmadığı gibi, çeviri süresini yaklaşık olarak 2/3 oranında azalttığı için, İDM derecelerinin *n=3* seçilmesinin getireceği başarı kaybı önemsenmeyebilir.

3. Kök bilgisini içermeyen İDM tipleri kullanıldığında, sistemin başarısı temel sistemden geriye düşmektedir. Bunun ana nedeni, kök bilgisini içermeyen İDM tiplerinin sözcük kökü seçiminde çok hata yapmalarıdır. Ancak kök bilgisi eklendiğinde belirgin bir başarı artışı sağlanmaktadır.

4. Kök bilgisnin kullanılmadığı durumlarda, biçimbirimsel bilgi miktarı arttıkça başarımın her durumda arttığı gözlenmiştir:

   $İDM_{Tip6} > İDM_{Tip3} > İDM_{Tip2}$

   Ancak kök bilgisinin eklenmesi ile seyrek veri sorunu gözlenmeye başlandığından bu sıralama geçerliliğini kaybetmektedir.

5. Diğerlerine göre daha fazla bilgi içeren, sözcük kökü ile son ÇG'deki biçimbirimsel bilgiler kullanılarak oluşturulan Tip-V dil modeli, seyrek veri sorunundan etkilenmiş görülmektedir.

6. *BLEUr* ve *BLEU* puanları arasındaki fark, sözcük kökünün doğru seçilmesine rağmen biçimbirimsel belirsizliğin doğru giderilememesi ve buna bağlı olarak da sözcüğe ait yanlış bir yüzeysel biçimin oluşturulmasından kaynaklanmaktadır.

8.3.5. İki Seviyeli İDM Başarımı

Bölüm 7.4'de anlatılan nedenlerden dolayı iki seviyeli istatistiksel değerlendirme alt yapısı oluşturulmuş ve değişik İDM tipleri ile deneyler yapılmıştır. Deneyler yapılırken, aktarım fonksiyonu olarak Model 2, İDM

derecesi *n=3*, 1. seviyede üretilecek çıktı sayısı *N=20* olarak seçilmiştir. Tablo 8-12 ve

Tablo 8-13'de, bu deneylerin başarımları, *BLEU* ve *BLEUr* puanları olarak verilmiştir.

Tablo 8-12 ve

Tablo 8-13'de zemini gri olan hücreler, ilgili dil modeli tipinin 1 seviyeli kullanımının *BLEU* ve *BLEUr* puanlarını göstermektedir.

Tablo 8-12 : İki seviyeli İDM indirgemesinin *BLEU* puanları

Model 2 n=3 N=20		2. Seviye İDM Türü					
		Tip-I	Tip-II	Tip-III	Tip-IV	Tip-V	Tip-VI
1. Seviye İDM Türü	Tip-I	31,03	28,61	32,32	28,82	31,99	32,92
	Tip-II	26,38	24,73	26,02	26,65	28,94	26,85
	Tip-III	32,46	28,18	26,39	32,48	33,12	28,81
	Tip-IV	29,04	28,83	34,36	33,34	32,78	34,03
	Tip-V	31,17	31,20	34,20	32,41	31,51	33,86
	Tip-VI	32,10	28,41	28,87	33,30	33,33	27,02

Tablo 8-13 : İki seviyeli İDM indirgemesinin *BLEUr* puanları

Model 2 n=3 N=20		2. Seviye İDM Türü					
		Tip-I	Tip-II	Tip-III	Tip-IV	Tip-V	Tip-VI
1. Seviye İDM Türü	Tip-I	37,77	36,55	37,47	38,01	38,37	38,11
	Tip-II	33,80	28,13	28,43	33,76	32,79	29,02
	Tip-III	37,71	30,87	30,05	37,31	35,77	31,39
	Tip-IV	38,90	37,50	38,38	38,62	38,87	39,31

	Tip-V	37,13	35,05	36,16	37,64	34,46	36,21
	Tip-VI	37,98	30,71	31,21	38,45	36,83	31,60

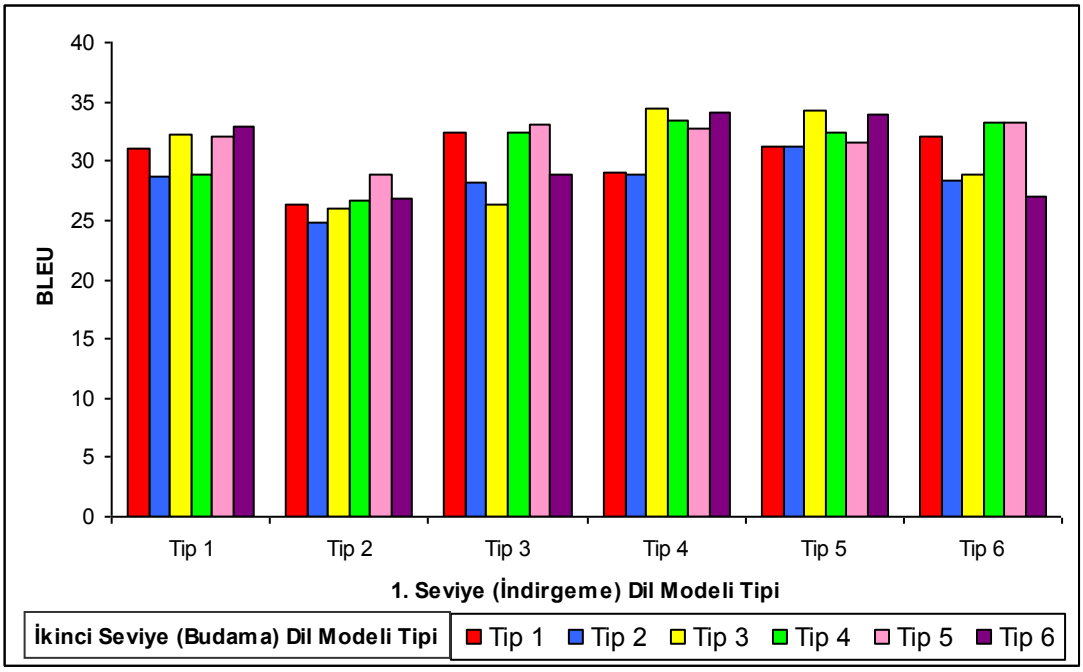

Şekil 8-4'de ise *BLEU* puanlarının çizelgesi verilmiştir. Tablolar ve çizelge incelendiğinde, tek seviyeli İDM kullanımında temel sistem puanlarının altında kalan Tip-II ve Tip-III İDM türleri 1. seviyede, daha geniş kapsamlı modelleme yapan diğer İDM türleri ise 2. seviyede kullanılırsa başarımın arttırılabildiği gözlenmiştir.

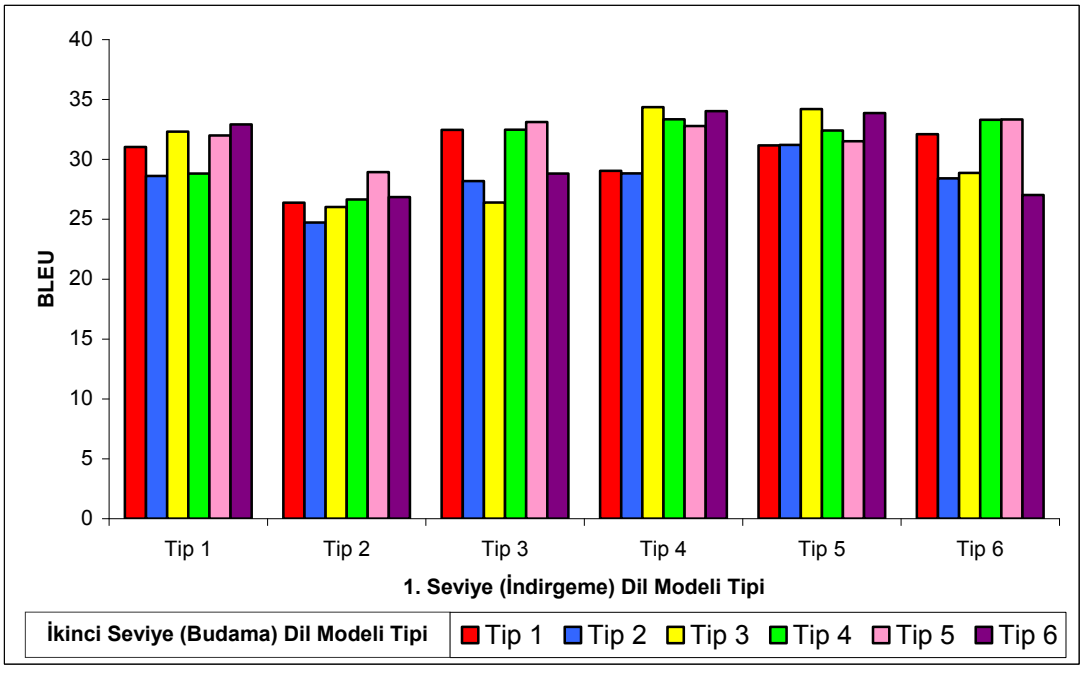

Şekil 8-4 : İki seviyeli İDM kullanımında başarım karşılaştırmaları

Şimdiye dek yapılan tüm deneylerin sonucunda, önerilen çeviri modeli temelinde gerçeklenen Türkmence-Türkçe çeviri sisteminin aktarım fonksiyonu bileşeni olarak Model 2'nin, İDM bileşeni olarak ise iki seviyeli bir kullanımla Tip-IV ve Tip-III'ün beraber kullanılmasının (*n=3, N=20* parametreleri ile) en yüksek başarımı verdiği görülmüştür.

8.4. Hatalı Durumların İncelenmesi

Gerçeklenen bütün iyileştirmelere karşın, önerilen aktarım yönteminin istatistiksel tabanlı oluşu, eğitim derleminin kısıtlı olması ve sözlük girdilerinin yetersiz olması gibi bazı nedenlerden dolayı hatalı durumlar da oluşmaktadır. Bu bölümde kısaca sık rastlanılan bazı hata türleri üzerinde durulacaktır.

Sistem genelinde kullanılan aktarım sözlüğü, [72] kaynağından yararlanılarak gerçeklenmiştir. Uygulamanın gerçekçiliğinin korunması adına, sözlük girdilerine birebir sadık kalınmıştır. Dolayısı ile bu sözlük girdilerindeki eksik anlamlar ve karşılıklar çeviri sırasında bazı sözcüklerin karşılıklarının, referanslarda kullanılan sözcüklerden farklı olmasına neden olmuştur:

Türkmence Söz.	Sözlükteki Karşılıklar	Ref. Tümcedeki Karşılık
gurna	topla, derle	sağla
bükgildi	çarpıntı, heyecan	tedirgin
mertebe	aşama, derece	seviye

Bu sorunun çözümü, sözlük girdilerinin ayrı bir çalışma ile yeniden düzenlenmesiyle sağlanabilir. İkinci bir çözüm önerisi ise, BalkaNET Projesi [73] kapsamında geliştirilen Türkçe kavramsal sözlükten yararlanarak, aynı anlama sahip sözcüklerden bir karşılıklar kümesinin dinamik olarak oluşturulmasıdır.

Tümce genelinde çalışan kurallar genellikle sözcükler arasındaki ünlü uyumunu düzeltmek amaçlıdır. Örneğin Türkçe'de isimden ayrı yazılan ***de/da*** bağlacı ve soru ekleri ***mi/mı/mü/mu*** bu kullanımlara örnektir.

Ancak bazı durumlarda yazımda görülen harf ile konuşma dilinde kullanılan harf farklılık göstermektedir. Aşağıdaki iki örneği ele alalım:

```
Son araba da geçti.          (1)
Son harf de tüketildi.       (2)
```

Görüldüğü gibi ***de/da*** bağlacından önceki her iki (***araba*** ve ***harf***) sözcüğün son seslisi (***a***), yazı dilinde kalın olmasına rağmen bu sözcüklerin okunuşları farklı

olduğundan takip eden bağlacın seslisi de değişiklik gösterir. İkinci örnekte bulunan ***a*** harfi aslında Türkçe sesçil abecede bulunan (art a - [α]) ve kalından çok ince olarak seslendirilen bir harftir [48].

Ancak aktarım kurallarının, yazımda değişiklik göstermeyen bu farklılığı sezmesi olası olmadığı için aşağıdaki hatalı çeviri üretilmektedir:

```
Son harf da tüketildi.        (2)
```

8.5. Çeviri Örnekleri

Bu bölümde bazı çeviri örnekleri verilerek, gerçeklenen sistemin başarısı ile *BLEU* puanlama sisteminin uyumu incelenecektir. Örneklerde kaynak tümce, sistem çıktısı aday tümce ve *BLEU* puanlamasında kullanılan iki adet referans tümce alt alta verilmiştir.

İlk olarak, üretilen aday çeviri ile, referans tümcelelerin anlamının büyük ölçüde sağlandığı, ancak *BLEU* tarafından düşük puanlandığı durumlara ilişkin örnekler sunulacaktır.

```
Kaynak      : bu mesele bilen adamlar gyzyklanypdyrlar , emmä ol
              soraga her taraply jogap berip_bilmändirler .

Aday Çeviri : bu meseleyle insanlar ilgilenmişler , ama o
              soruya her yönlü cevap verememişler .

Referans 0  : bu mesele ile insanlar ilgilenmişlerdir , ama bu
              soruya her yönü ile cevap verememişlerdir .

Referans 1  : bu meseleyle insanlar ilgilenmişlerdir , ama bu
              soruya her yönü ile cevap verememişlerdir .
```

Kaynak tümcede "_" işareti ile birleştirilen sözcükler, uygulama tarafından bir ÇSG olarak işaretlenerek Türkçe'ye doğru olarak çevrilebilmiştir. Aday çeviri ve referans karşılaştırıldığında anlamsal açıdan çok büyük bir farklılık olmamasına karşın, bu tümcenin *BLEU* puanının 25,82 çıkması, başarım puanlamasında sözcüklerin yüzeysel biçimlerinin eşleşmelerinin ne kadar önemli olduğunun bir göstergesi olarak yorumlanmalıdır. Benzer şekilde, çeviri ile referans arasında hemen hemen hiçbir anlam farkı içermeyen aşağıdaki örnek için dahi *BLEU* puanı 56,69 olarak hesaplanmıştır:

```
Kaynak      : bu dana adam birden gülmesini goÿup aglamaga
              başlapdyr.

Aday Çeviri : bu bilgin adam birden gülmesini bırakarak ağlamaya
              başlamış.
```

```
Referans 0  : bu bilgin insan birden gülmesini kesip ağlamaya
              başlamış

Referans 1  : bu bilgin insan birden gülmesini bırakıp ağlamaya
              başlamış.
```

Bu nedenle genel sistemin *BLEU* puanı yaklaşık 34 iken, aslında üretilen çevirilerin referanslarla uyumunun çok daha yüksek olduğu yorumu getirilebilir.

İncelenmeye değer bir diğer durum ise, sistem tarafından üretilen bazı aday tümcelerde, referanslarda geçen sözcüklerin eş anlamlılarının tercih edilmesi nedeniyle *BLEU* puanının düşük çıkması durumudur. Sözcük kökünün aktarımındaki seçim farklılıklarından kaynaklanan durumlar, *BLEU* yönteminde çok sayıda referans tümce kullanılarak düzeltilmeye çalışılmaktadır. Ancak bizim değerlendirme yaptığımız tümce kümesinde, her tümce için iki adet referans çeviri bulunmakta ve bazı eş anlamlı sözcükler referanslarda geçmediğinden toplam *BLEU* puanlamasını düşürmektedir. Aşağıda bu duruma uyan bir örnek tümce verilmiştir:

```
Kaynak         : mertebesini bilmeýän adamlary diri hasap etmegin .

Aday Çeviri    : derecesini bilmeyen insanları sağ hesap etme .

Referans 0     : seviyesini bilmeyen adamları diri sayma .

Referans 1     : mertebesini bilmeyen adamları diri hesap etme .
```

Yukarıdaki örnek tümcede, "***mertebe***" Türkmence sözcüğünün karşılığı olarak sistem "***derece***" kökünü seçmiştir. Ancak bu kök, referans tümcelerin ikisinde de kullanılmamıştır. Benzer şekilde aday tümce oluşturulurken sistemin tercih ettiği "***insan***" ve "***sağ***" sözcük kökleri yerine referans tümcelerde farklı sözcükler kullanılmıştır. Bu hali ile 31.62 olarak hesaplanan *BLEU* puanı, aday tümcedeki "***derece***", "***adam***" ve "***sağ***" kökleri sırası ile "***mertebe***", "***insan***" ve "***diri***" kökleri ile değiştirilince 75.98 olarak hesaplanmaktadır. Burada çıkartılacak sonuç ise, sistemin çıktılarının referanslarla uyumunun, *BLEU* puanından daha yüksek bir derecede olduğudur.

Çeviriler incelendiğinde görülen sorunlardan bir diğeri de kısa tümcelerde hata yapma oranının artmasıdır. Aşağıda bu duruma uyan bir örnek verilmiştir:

```
Kaynak         : nebsim janym agyrdy .

Aday Çeviri    : çok kişim ağrıdı .

Referans 0     : buna çok canım sıkıldı .
```

```
Referans 1     : çok canım sıkıldı .
```

Bu örnekte, Türkmence "***jan***" sözcüğü "***kişi***" anlamı ile aktarılmıştır. Yine benzer bir hata aşağıdaki örnekte de görülebilir:

```
Kaynak         : hem gülki hem gözÿaş !
Aday Çeviri    : da gülme de gözyaşı !
Referans 0     : hem kahkaha hem gözyaşı !
Referans 1     : hem kahkaha hem gözyaşı !
```

Bu örnekte ise, Türkçe'de "***de***" ve "***hem***" bağlaçlarının görevini gören Türkmence "***hem***" sözcüğü aktarılırken "***de***" bağlacı anlamıyla aktarılmıştır. Özellikle tümcenin başındaki sözcükler için yeterli sayıda geçmiş sözcük bulunmadığı bunlara benzer kısa tümcelerde, yukarıdaki gibi hatalı çeviri örnekleri görülebilmektedir.

8.6. Aktarım Süreleri

Bulunan en iyi parametrelerle çalıştırılması durumunda, geliştirilen aktarım sisteminin çıktı üretmesi için geçen toplam süre ve her bir bileşenin işlem süresi aşağıdaki

Tablo 8-14'de verilmiştir. Tablodaki sürelerin hesaplanması için, çeviri sistemi, standart bir kişisel bilgisayar [13] üzerinde, 255 giriş tümcesi için 10 defa çalıştırılmış koşturulmuş ve her çalışma sonunda ölçülen sürelerin ortalamasının alınmıştır [14].

Tablo 8-14 : Aktarım süreleri

Tümce/Sözcük Ayırıcı	0,67 s
Türkmence Biçimbirimsel Çözümleme	0,19 s
ÇSG İşleyici	8,79 s
Biçimbirimsel Yapıların Aktarımı	0,82 s
Kök Aktarımı	1,61 s
1. Seviye İDM	5,45 s
2. Seviye İDM	22,92 s

[13] 1.86 MHz frekanslı çift çekirdekli işlemci, 1 GB ana bellek

[14] İDM dosyalarının yüklenmesi için gereken süre hesaplamalara dahil edilmemiştir.

Yapısal Biçim Düzeyinde Tümce Geneli Kurallar	3,45 s
Türkçe Biçimbirimsel Üretici	44,98 s
Yüzeysel Biçim Düzeyinde Tümce Geneli Kurallar	0,56 s
Toplam Süre	88,79 s

Tablo incelendiğinde, sistemin saniyede 2,88 tümce çevirdiği hesaplanabilmektedir. Bileşenlerin çalışma süreleri karşılaştırıldığında, Türkçe biçimbirimsel üreticinin en çok süreyi kullandığı görülmektedir. Türkmence biçimbirimsel çözümleyici ise çok daha kısa sürede çalışmaktadır. Türkçe için kullanılan üretici araç, genel kullanıma açık geniş kapsamlı bir araçtır. Oysa Türkmence için geliştirilen biçimbirimsel çözümleyicinin sözlük boyutu, sadece sınama kümesindeki sözcükleri işleyebilecek kadar dar kapsamlıdır. İkinci seviye İDM bileşeninin, birinci seviye İDM'den daha uzun sürmesinin nedeni ise birinci seviyede HMM ve geliştirilmiş Viterbi algoritması ile çabucak sonuca gidebilirken, ikinci seviyede üretilen N aday tümce üzerine bir HMM oluşturulamamaktadır. İkinci seviyede oluşan N aday tümcenin her birisi için olasılık ayrı ayrı hesaplanması işlemi de uzun sürmektedir. Sistemin kapsamının genişlemesi durumunda Türkmence biçimbirimsel çözümleme ve kök aktarımı bileşenlerinin çalışma sürelerinin uzayacağı kesindir. Ayrıca tüm bileşenlerin çalışma süreleri, giriş tümcesi ile orantılı olarak artmaktadır.

9. DEĞERLENDİRME VE TARTIŞMA

Bu tez çalışması kapsamında, dilbilgisel açıdan benzerlikler taşıyan akraba diller arasında bilgisayarlı çeviri yöntemleri incelenmiş, özellikle seçilen dil çiftinin bitişken olması durumu göz önünde bulundurularak bir çeviri yöntemi önerilmiştir. Önerilen çeviri yöntemi, hem bilgi tabanlı ve kural temelli hem de istatistiksel bileşenlerden oluşan karma (hibrid) bir modeldir. Çoğu kez, kural tabanlı çeviri sistemlerinin kural havuzu çok karmaşık bir hale gelir ve zamanla yönetilmesi zorlaşır. Diğer yandan istatistiksel sistemler, tasarımcıları bu karmaşadan kurtarmaktadır ancak başarılı bir çeviri için yoğun miktarda çift dilli tümce derlemlerinin hazırlanmasını şart koşmaktadır. Bu tür bir derlemin hazırlanamadığı durumlarda, istatistiksel yöntemler kullanılamamaktadır. Önerdiğimiz sistem, akraba diller arasında, göreceli olarak basit kurallarla, belirli bir belirsizlik düzeyi korunarak çeviri yapılmasını ve belirsizliklerin hedef dilde oluşturulan istatistiksel yapılarla giderilmesini öngörmektedir. Böylelikle akraba dil çifleri için istatistiksel ve bilgi-tabanlı çeviri yöntemlerinin olumlu özellikleri birleştirilerek bir çeviri modeli önerilmiştir. Bu çeviri modeli, özellikle bitişken dil çiftleri arasında çeviri yapacak biçimde tasarlanmıştır.

Önerilen çeviri modeli iki temel bileşenden oluşmaktadır :

1) aktarım fonksiyonu ve

2) hedef dilde istatistiksel dil modeli.

Aktarım fonksiyonunun tasarımı için, özellikle bitişken diller için üç değişik model geliştirilmiştir. Hedef dil için istatistiksel dil modeli oluşturulması konusunda da, bitişken dillerin özellikleri göz önünde bulundurularak altı farklı İDM tipi tanımlanmıştır.

Aktarım fonksiyonu, biçimbirimsel çözümleme destekli doğrudan aktarım olarak düşünülebilir. Kaynak dildeki sözcüklerin biçimbirimsel çözümlemesi yapıldıktan sonra çift dilli sözlük yardımı ile sözcük köklerinin aktarımı sağlanır. Daha sonra çözümlemelerdeki biçimbirimsel yapılar hedef dile aktarılır. Bu fonksiyon içerisinde

iki farklı belirsizlik kaynağı bulunmaktadır. Birincisi biçimbirimsel çözümlemede, ikincisi ise sözcük kökünün aktarılmasında ortaya çıkmaktadır.

Yöntemin ikinci bileşeni olan istatistiksel dil modeli ile de bu belirsizlikler, istatistiksel yöntemlerle giderilmeye çalışılarak en yüksek olasılığa sahip tümce, aday çeviri olarak üretilir. İstatistiksel çeviride kullanılan İDM ile benzer şekilde kullanılan bu bileşenin, sadece hedef dil üzerinde hazırlanması yeterlidir. Böylelikle her iki dil arasında çok sayıda çift dilli tümcenin hizalanması ile oluşturulacak bir eğitim kümesine gereksinim duyulmamaktadır.

Akraba diller arasında önerdiğimiz bu çeviri modeli, Türk Dilleri arasında çeviri amacıyla irdelenmiş, aktarım modellerinin ve dil modeli tiplerinin başarımlarını ölçmek amacıyla Türkmence-Türkçe dil çifti için bir çeviri sistemi gerçeklenmiştir. Gerçeklenen sistemle, önerilen üç aktarım fonksiyonu modeli ve altı farklı İDM tipi kullanılarak sınama derlemi üzerinde başarımlar ölçülmüştür.

Önerdiğimiz modeller, kaynak dilde biçimbirimsel belirsizlik giderici bulunmasını zorunlu kılmamaktadır. Önceki çalışmalardan farklı olarak biçimbirimsel belirsizlik hedef dilde giderilmektedir. Bu özellik, biçimbirimsel belirsizlik giderici araçları bulunmayan Türkçe dışındaki diğer Türk Dilleri arasında çeviri yapabilmek için çok önemlidir.

Yapılan deneyler sonucunda, geliştirilen modeller ve gerçeklenen sistem, sınama derlemindeki Türkmence tümceleri, referans tümcelerdeki anlamları da koruyacak şekilde, Türkçe'ye aktarabilmiştir. Bu da, birçok bilgisayarlı çeviri sisteminin geliştirilmesinde harcanan emekten çok daha az bir çalışma ile Türk Dilleri arasında çeviri yapabilen sistemlerin tasarlanabileceğini göstermektedir. Her ne kadar tez çalışması kapsamında Türk Dilleri incelenmiş olsa da, geliştirilen modeller, bütün akraba-bitişken dil çiftleri için uygulanabilir niteliktedir.

Sonuçlar incelendiğinde, önerilen aktarım fonksiyonlarından Model 2'nin, iki seviyeli İDM kullanımı ile (1.Seviye : İDM Tip-IV, 2.Seviye : İDM Tip-III, $N=20$, $n=3$ paramterleriyle) birlikte en yüksek başarıyı sağladığı gözlenmiştir.

Uygulamada, istatistiksel model hariç diğer tüm bileşenler SDD'ler ile yapılmış olduğundan, gerçeklenen çeviri sistemi ters yönde de rahatlıkla kullanılabilir. Doğal olarak ters yönde kullanımda hedef dil için İDM'nin yeniden oluşturulması gereklidir. Buradan hareketle Türkçe'den Türkmence'ye çeviri sisteminin

gerçeklenmesi çok zor görünmemektedir. Üstelik Türkçe için biçimbirimsel belirsizlik çalışmaları bulunduğundan, sistemin çözmek zorunda kalacağı biçimbirimsel belirsizlik de yok olur, İDM sadece sözcüksel belirsizliğin çözümünde kullanılır.

Gerçeklenen tez çalışmasının bilimsel katkısı, aşağıdaki maddelerle özetlenebilir:

- Akraba ve bitişken dil çiftleri arasında bilgisayarlı çeviri için kural tabanlı ve istatistiksel bileşenlerden oluşan karma bir yöntem önerilmiştir.
- Önerilen modeller çerçevesinde Türk Dilleri arasında bilgisayarlı çeviri konusu incelenmiştir.
- Önerilen modellerin etkinliği ve başarımı, Türkmence'den Türkçe'ye çeviri yapan bir sistem gerçeklenerek sınanmıştır.
- Geliştirilen sistem ile, diğer Türk Dilleri arasında bilgisayarlı çeviri gerçeklemek için de kullanılabilecek bir altyapı ortaya konulmuştur.

Çalışma sırasında karşılaşılan çeşitli güçlükler ve sorunlar aşağıda sıralanmıştır:

- İstatistiksel yöntemlerin en büyük gereksinimi, yüklü miktarda eğitim verisidir. İngilizce, Almanca gibi yaygın kullanılan bir çok dil için bu tür eğitim derlemleri kullanıma hazır ve erişilebilir bir durumdayken, Türkçe için kullanılan derlemin büyüklüğü henüz yeterli seviyede değildir. Uygulamada yaklaşık 1M çözümlenmiş sözcük üzerinden çıkartılan İDM, hem sözcük köklerinin hem de karşılaşılan biçimbirimsel çözümleme tiplerinin çeşitliliği yüzünden seyrek veri sorunundan değişik oranlarda etkilenmektedir.
- Türk Dilleri, özellikle uygulamanın geliştirildiği Türkmence dili hakkında doğal dil işleme yaklaşımlı dil bilgisi kaynaklarının yetersiz olması, kaynak Türk dilinde biçimbirimsel çözümleyicinin gerçeklenmesi ve aktarım kurallarının hazırlanmasında büyük sıkıntılara yol açmıştır.
- Türkçe'de belirli bir ölçekte olmasına karşın, diğer bir çok Türk Dili üzerinde yeterli sayıda bilgisayarlı dil işleme çalışması ve kullanılabilir araçların olmaması, sistemin geliştirme süresinin uzamasını ve geliştirilen sistemin başarısını düşürmektedir. Örneğin Türkçe dışındaki hemen hemen hiçbir dil için (Kırım Tatarcası hariç) kullanılabilir genel amaçlı bir biçimbirimsel çözümleyiciye erişilememiştir. Benzer şekilde biçimbirimsel belirsizlik

giderilmesi için de bir araç olmadığı için bu biçimbirimsel belirsizlik bir çok aşama boyunca taşınmakta ve potansiyel hatalı karşılıklar üretilmektedir.

- Önerilen modellerin ve İDM tiplerinin başarımlarının karşılaştırılmasında kullanılan BLEU ölçütü, Türk dillerinin yapısına çok uygun değildir. Değişken sözcük/sözcük öbeği sıralaması, zengin yapım ve çekim ekleri dolayısı ile sözcüklerin yüzeysel biçimlerinin farklı oluşabilmesi, BLEU değerlendirme sistemi kapsamında ciddi puan kayıplarına neden olmaktadır.
- BLEU puanlarının hesaplanması için yaygın olarak dört referans tümce kullanılırken, bizim bulabildiğimiz referans çeviri sayısı iki olmuştur. Ayrıca daha sağlıklı bir değerlendirme için sınama derleminin boyutu da arttırılmalıdır.

Çalışma kapsamında eksik görülen ve ileriki çalışmalarda tamamlanması beklenen noktalar şunlardır:

- Gerçeklenen uygulama sisteminde, Türkmence için tasarlanan biçimbirimsel çözümleyici SDD ile tasarlanmış olduğundan ters yönde üretim amacıyla da kullanılabilmektedir. Bu sayede aynı araç, örneğin Türkçe'den Türkmence'ye çeviri yaparken de kullanılabilecektir. Ancak bu çalışma kapsamında sadece çözümleme yönünde kullanıldığı için, ters yönde çalıştırılması durumu üzerinde fazla durulmamıştır. Geliştirilen Türkmence biçimbirimsel çözümleyici SDD ters yönde üretici olarak çalıştırılırsa, geçersiz ve fazlalık bazı çıktılar üretmektedir. Bu konuda bir çalışma yapılıp Türkmence biçimbirimsel çözümleyici/üretici aracın üretim yönündeki başarımı yükseltilmelidir.
- Geliştirilen Türkmence biçimbirimsel çözümleyicinin güncel sürümü, sadece sınama kümesindeki sözcük kökleri ile yaygın kullanılan bazı sözcük köklerini içermektedir. Genel amaçlı bir sistemin geliştirilmesi için alt sözlükler, tüm sözcük köklerini kapsayacak şekilde güncellenmelidir.
- Benzer şekilde geliştirilen sistemin aktarım sözlüğü, sadece sınama derlemindeki sözcüklerin köklerini içermektedir. Genel amaçlı bir sistemin tasarımı için bu aktarım sözlüğünün kapsamının genişletilmesi gereklidir.

Gerçekleştirdiğimiz çalışmayı geliştirmek üzere sonradan yapılabilecek tamamlayıcı nitelikli çalışmalar aşağıda verilmiştir.

- Diğer Türk Dili çiftlerinde çeviri yapılabilmesi için, her Türk Dili için biçimbirimsel çözümleyicinin ve üreticinin gerçeklenmesi uygun olacaktır. Geliştirilecek araçlar, çeviri sistemlerinin geliştirilmesinde kullanılabileceği gibi diğer bir çok DDİ çalışması için mutlak yapılması gereken bir işlevi yerine getirecektir.
- Farklı türlerde (haber, hikaye, siyasi,…) metinlerden ve bunların referans çevirilerinden oluşan yeni bir sınama derlemi oluşturarak sistemin, bu genel konulu derlemdeki başarısının ölçülmesi, sistemin genel kullanıma açılması yönünde önemli bir değerlendirme olanağı sağlayacaktır.

10. KAYNAKLAR

[1] T. Banguoğlu, *Türkçenin Grameri*: Türk Dil Kurumu, 2000.

[2] M. Nagao, "A Framework of a Mechanical Translation Between Japanese and English by Analogy Principle," in *Artificial and Human Intelligence*, A. E. a. R. Banerji, Ed. North-Holland, 1984.

[3] J. Hajič, "RUSLAN - An MT System Between Closely Related Languages," in *Third Conference of the European Chapter of the Association for Computational Linguistics (EACL'87)* Copenhagen, Denmark, 1987.

[4] J. Hajič, J. Hric, and V. Kuboň, "Machine translation of very close languages," in *Proceedings of the sixth conference on Applied natural language processing* Proceedings of the sixth conference on Applied natural language processing Morgan Kaufmann Publishers Inc., 2000, pp. 7-12.

[5] J. Hajič, P. Homola, and V. Kuboň, "A simple multilingual machine translation system," in *MT Summit IX* New Orleans, USA, 2003.

[6] B. Dvořák, P. Homola, and V. Kuboň, "Exploiting similarity in the MT into a minority language," in *LREC-2006: Fifth International Conference on Language Resources and Evaluation. 5th SALTMIL Workshop on Minority Languages: "Strategies for developing machine translation for minority languages"* Genoa, Italy, 2006.

[7] R. Canals, A. Esteve, A. Garrido, M. I. Guardiola, A. Iturraspe-Bellver, S. Montserrat, P. Pérez-Antón, S. Ortiz, H. Pastor, and M. L. Forcada, "interNOSTRUM: a Spanish-Catalan Machine Translation System," *Machine Translation Review,* vol. 11, pp. 21-25, 2000.

[8] A. M.Corbi-Bellot, M. L. Forcada, S. Ortíz-Rojas, J. A. Pérez-Ortiz, G. Ramírez-Sánchez, F. Sánchez-Martínez, I. Alegria, A. Mayor, and K. Sarasola, "An open-source shallow-transfer machine translation engine for the Romance languages of Spain," in *10th EAMT conference "Practical applications of machine translation"* Budapest, Hungary, 2006.

[9] C. A. i. Oller and M. L. Forcada, "Open-source machine translation between small languages : Catalan and Aranese Occitan," in *LREC-2006: Fifth International Conference on Language Resources and Evaluation. 5th SALTMIL Workshop on Minority Languages: "Strategies for developing machine translation for minority languages"* Genoa, Italy, 2006.

[10] J. Tomás and F. Casacuberta, "Monotone statistical translation using word groups," in *MT Summit VIII: Machine Translation in the Information Age* Santiago de Compostela, Spain, 2001.

[11] İ. Hamzaoğlu, "Machine translation from Turkish to other Turkic languages and an implementation for the Azeri languages," in *Institute for Graduate Studies in Science and Engineering*. vol. MSc Thesis İstanbul: Bogazici University, 1993.

[12] K. Altıntaş, "Turkish to Crimean Tatar Machine Translation System," in *Bilgisayar Mühendisliği Bölümü*. vol. MSc Ankara: Bilkent Üniversitesi, 2000.

[13] K. Oflazer, "Two-level Description of Turkish Morphology," *Literary and Linguistic Computing,* vol. 9, pp. 137-148, 1995.

[14] K. Altıntaş and İ. Çiçekli, "A Morphological Analyser for Crimean Tatar," in *Proceedings of the 10th Turkish Symposium on Artificial Intelligence and Neural Networks, TAINN* North Cyprus, 2001, pp. 180-189.

[15] K. Koskenniemi, "Two-Level Morphology : A General Computational Model for Word Form Recognition and Production," Department of General Linguistics, University of Helsinki 1983.

[16] L. Karttunen, "KIMMO : A General Morphological Processor," in *Texas Linguistic Forum*, Texas, USA, 1983, pp. 163-186.

[17] E. L. Antworth, "PC-KIMMO: A Two-Level Processor for Morphological Analysis," Summer Institute of Linguistics, Dallas, Texas, USA 1990.

[18] R. Sproat, *Morphology and Computation*: MIT Press 1992.

[19] L. Karttunen and K. Wittenburg, "A Two-Level Morphological Analysis of English," in *Texas Linguistic Forum*, Texas, USA, 1983, pp. 217-228.

[20] R. Khan, "A Two-Level Morphological Analysis of Rumanian," in *Texas Linguistic Forum*, Texas, USA, 1983, pp. 253-270.

[21] K. Koskenniemi, "An Application of the Two-Level Model to Finnish," University of Helsinki Department of General Linguistics (1985.

[22] S. Lun, "A Two-Level Morphological Analysis of French," in *Texas Linguistic Forum*, Texas, USA, 1983, pp. 271-278.

[23] L. Karttunen, T. Gaal, and A. Kempe, "Xerox Finite-State Tool," XEROX Research Centre, Europe, Technical Report 1997.

[24] L. R. Bahl, F. Jelinek, and R. L. Mercer, "A Maximum Likelihood Approach to Continous Speech Recognition," *IEEE TRANSACTIONS ON PATTERN ANALYSIS AND MACHINE INTELLIGENCE,* vol. 5, pp. 179-190, 1983.

[25] D. Jurafsky and J. H. Martin, *Speech and Language Processing: An Introduction to Natural Language Processing, Computational Linguistics and Speech Recognition*: Prentice Hall, 2000.

[26] H. Jeffreys, *Theory of Probability*, 2nd ed.: Clarendon Press, Oxford, 1948.

[27] I. H. Witten and T. C. Bell, "The Zero-Frequency Problem : Estimating the Probabilities of Novel Events in Adaptive Text Comprassion," *IEEE Transactions on Information Theory*, vol. 37, pp. 1085-1094, 1991.

[28] W. A. Gale, "Good-Turing Smoothing without Tears," Bell Labs 1994.

[29] S. M. Katz, "Estimation of Probabilities from Sparse Data for Language Model Component of a Speech Recognizer," *IEEE Transactions on Acoustics, Speech and Signal Processing*, vol. 35:3, pp. 400-401, 1987.

[30] C. D. Manning and H. Schütze, *Foundations of Statistical Natural Language Processing*. Cambridge: The MIT Press, 1999.

[31] J. T. Goodman, "A Bit of Progress in Language Modeling Extended Version," Redmond, USA: Microsoft Research, 2001.

[32] F. Jelinek, R. L. Mercer, L. Bahl, and J. K. Baker, "Perplexity - A Measure of the Difficulty of Speech Recognition Tasks," *Journal of the Acoustical Society of America*, 1977.

[33] J. Chandioux, "MÉTÉO : un systéme opérationnel pour la traduction automatique des bulletins météorologiques destinés au grand public.," *Meta,* vol. 21, pp. 127-133, 1976.

[34] P. F. Brown, J. Cocke, S. A. D. Pietra, V. J. D. Pietra, F. Jelinek, J. D. Lafferty, R. L. Mercer, and P. S. Roossin, "A Statistical Approach to Machine Translation," *Computational Linguistics,* vol. 16, pp. 79-85, 1990.

[35] P. F. Brown, V. J. D. Pietra, S. A. D. Pietra, and R. L. Mercer, "The mathematics of statistical machine translation: parameter estimation," *Computational Linguistics* vol. 19, pp. 263 - 311, 1993.

[36] P. Koehn, "Noun Phrase Translation." vol. PhD Thesis Los Angeles: University of Southern California, 2003.

[37] R. D. Brown, "Example-Based Machine Translation in the Pangloss System," in *The 16th International Conference on Computational Linguistics (COLING-96)* Copenhagen, Denmark, 1996.

[38] H. A. Guvenir and I. Cicekli, "Learning Translation Templates from Examples," *Information Systems,* vol. 23, pp. 353-363, 1998.

[39] H. Somers, "Review Article: Example-based Machine Translation." vol. 14: Kluwer Academic Publishers, 1999, pp. 113-157.

[40] K. Papineni, S. Roukos, T. Ward, and W.-J. J. Zhu, "BLEU : A Mehtod for Automatic Evaluation of Machine Translation," in *Association of Computational Linguistics, ACL'02* Philadelphia, PA, USA, 2002.

[41] "NIST Report - Automatic Evaluation of Machine Translation Quality Using N-gram Co-Occurrence Statistics," 2002.

[42] C. Callison-Burch, M. Osborne, and P. Koehn, "Re-evaluating the Role of BLEU in Machine Translation Research," in *Conference of the European Chapter of the Association for Computational Linguistics (EACL'06)* Trento, Italy, 2006.

[43] I. D. Melamed, R. Green, and J. P. Turian, "Precision and Recall of Machine Translation," in *HLT-NAACL 2003,* 2003.

[44] S. Banerjee and A. Lavie, "METEOR: An Automatic Metric for MT Evaluation with Improved Correlation with Human Judgments," in *ACL Workshop on Intrinsic and Extrinsic Evaluation Measures for Machine Translation and/or Summarization* Ann Arbor, MI, USA, 2005.

[45] K. Oflazer, Ö. Çetinoğlu, and B. Say, "Integrating Morphology with Multi-word Expression Processing in Turkish," in *The ACL 2004 Workshop on Multiword Expressions:Integrating Processing* Barcelona, Spain, 2004.

[46] D. Z. H. Tür, K. Oflazer, and G. Tür, "Statistical Morphological Disambiguation for Agglutinative Languages," *Computers and the Humanities*, vol. 36, pp. 381-410, 2002.

[47] K. Oflazer, "Dependency Parsing with a Extended Finite State Approach," in *College Park, Maryland*, 1999.

[48] M. Hengirmen, *Türkçe Dilbilgisi*. Ankara: Engin Yayıncılık, 2000.

[49] T. Tekin, "Türk Dilleri Ailesi," in *www.turkoloji.com.tr.tc*, 2006.

[50] http://www.enthonologue.com, 2006.

[51] K. Oflazer and İ. Kuruöz, "Tagging and Morphological Disambiguation of Turkish Text," in *The Fourth ACL Conference on Applied Natural Language Processing* Stuttgart: ACL, 1994.

[52] K. Oflazer and G. Tür, "Combining Hand-crafted Rules and Unsupervised Learning in Constraint-based Morphological Disambiguation," in *Conference on Empirical Methods in Natural Language Processing, EMNLP* Somerset, New Jersey: Association for Computational Linguistics, 1996.

[53] D. Yüret and F. Türe, "Learning Morphological Disambiguation Rules for Turkish," in *North American Chapter of the Association for Computational Linguistics Annual Meeting (HLT-NAACL 2006)* New York City, 2006.

[54] G. D. Fomey, "The Viterbi Algorithm," *IEEE Proceedings*, vol. 61, pp. 268-278, 1973.

[55] G. Tür, "A Statistical Information Extraction System for Turkish," in *The Department of Computer Engineering*. vol. PhD Thesis Ankara: Bilkent University, 2000.

[56] A. C. Tantuğ, E. Adalı, and K. Oflazer, "A Prototype Machine Translation System Between Turkmen and Turkish," in *Fifteenth Turkish Symposium on Artificial Intelligence and Neural Networks, TAINN* Gökova, Muğla, Türkiye, 2006.

[57] A. C. Tantuğ, E. Adalı, and K. Oflazer, "Computer Analysis of the Turkmen Language Morphology," in *FinTAL, Lecture Notes in Computer Science*. vol. 4139: Springer, 2006, pp. 186-193.

[58] S. Arnazarow, A. Borjakow, M. Saruhanow, M. Söyegow, and B. Hojayew, *Türkmen Dilinin Grammatikasy*. Ankara: Türk Dil Kurumu, 2000.

[59] M. Kara, *Türkmence (Giriş-Gramer-Metinler-Sözlük)*. Ankara: Kültür Bakanlığı Yayınları, 2000.

[60] B. Sarı and N. Güder, *Türkmencenin Grameri - I (Fonetika-Ses Bilgisi)*: Türk Dünyası Gençlerinin Mahtumkulu Yayın Birliği, 1998.

[61] B. Sarı and N. Güder, *Türkmencenin Grameri - II (Morfologiya – Şekil Bilgisi)*: Türk Dünyası Gençlerinin Mahtumkulu Yayın Birliği, 1998.

[62] B. Sarı and N. Güder, *Türkmencenin Grameri - III (Sintaksis)*: Türk Dünyası Gençlerinin Mahtumkulu Yayın Birliği, 1998.

[63] L. V. Clark, *Turkmen reference grammar*. Wiesbaden: Harrassowitz Verlag, 1998.

[64] K. R. Beesley and L. Karttunen, *Finite State Morphology*. Stanford: CSLI Publications, 2003.

[65] P. Clarkson and P. R. Rosenfeld, "Statistical Language Modeling Using CMU-Cambridge Toolkit," in *ESCA Eurospeech'97*, 1997.

[66] A. Stolcke, "SRILM - An Extensible Language Modeling Toolkit," in *International Conference on Spoken Language Processing* Denver, Colorado, 2002.

[67] Y.-L. Chow and R. Schwartz, "The N-Best Algorithm: An Efficient Procedure for Finding Top N Sentence Hypotheses," in *Proceedings of a Workshop on Speech and Natural Language* Philadelphia, 1989.

[68] L. S. Oliveira, R. S. F. Bortolozzi, and C. Y. Suen, "Automatic Recognition of Handwritten Numerical Strings: A Recognition and Verification Strategy," *IEEE Transactions on Pattern Analysis and Machine Intelligence,* vol. 24, pp. 1438-1554, 2002.

[69] L. E. S. Oliviera, "Automatic Recognition of Handwritten Numerical Strings," in *ÉCOLE DE TECHNOLOGIE SUPÉRIEURE*. vol. PhD Quebec: UNIVERSITÉ DU QUÉBEC, 2003.

[70] K. Oflazer and G. Tür, "Morphological Disambiguation by Voting Constraints," in *The Thirty-Fifth Annual Meeting of the ACL and Eighth Conference of the EACL* Somerset, New Jersey, 1997.

[71] E. E. Erguvanlı, "The Function of Word Order in Turkish." vol. PhD Los Angeles: University of California, 1979.

[72] T. Tekin, M. Ölmez, E. Ceylan, Z. K. Ölmez, and S. Eker, *Türkmence-Türkçe Sözlük*. İstanbul: Simurg Yayınları, 1995.

[73] S. Stamou, K. Oflazer, K. Pala, D. Christoudoulakis, D. Cristea, D. Tufis, S. Koeva, G. Totkov, D. Dutoit, and M. Grigoriadou, "Balkanet: A multilingual Semantic Network for Balkan Languages," in *First International WordNet Conference* Mysore India, 2002.

EK A – BİÇİMBİRİMSEL ETİKETLERİN AÇIKLAMALARI

Etiket	Açıklama
+Noun	İsim
+Adj	Sıfat
+Adverb	Belirteç
+Det	Belirteç
+Dup	İkileme
+Interj	Ünlem
+Ques	Soru
+Verb	Eylem
+Postp	İlgeç
+Num	Sayı
+Pron	Zamir
+Punc	İşaretleme
+Card	Asıl Sayı
+Ord	Sırasal Sayı
+Percent	Yüzdesel Sayı
+Range	Aralıksal Sayı
+Real	Gerçel Sayı
+Ratio	Oransal Sayı
+Distrib	Üleştirme Sayı
+Time	Zaman Belirteci
+Inf	Mastar
+Prop	Özel İsim
+PastPart	Geçmiş Zaman Ortacı
+FutPart	Gelecek Zaman Ortacı
+PresPart	Geniş Zaman Ortacı
+Demons	İşaret Zamiri
+Ques	Soru Zamiri

+Reflex	Dönüşlü Zamir
+Pers	Kişi Zamiri
+Quan	Belgisiz Zamir
+A1sg	1. Tekil Şahıs Uyum Özelliği
+A2sg	2. Tekil Şahıs Uyum Özelliği
+A3sg	3. Tekil Şahıs Uyum Özelliği
+A1pl	1. Çoğul Şahıs Uyum Özelliği
+A2pl	2. Çoğul Şahıs Uyum Özelliği
+A3pl	3. Çoğul Şahıs Uyum Özelliği
+P1sg	1. Tekil Şahıs İyelik Eki
+P2sg	2. Tekil Şahıs İyelik Eki
+P3sg	3. Tekil Şahıs İyelik Eki
+P1pl	1. Çoğul Şahıs İyelik Eki
+P2pl	2. Çoğul Şahıs İyelik Eki
+P3pl	3. Çoğul Şahıs İyelik Eki
+Pnon	Belirsiz İyelik
+Nom	Yalın Durum
+Acc	Belirtme Durumu
+Dat	Yönelme Durumu
+Abl	Çıkma Durumu
+Loc	Kalma Durumu
+Gen	Tamlayan Durumu
+Ins	Aracılık Durumu
+Equ	Eşitlik Durumu
^DB+Verb+Pass	Edilgen Çatı
^DB+Verb+Caus	Ettirgen Çatı
^DB+Verb+Reflex	Yansımalı Çatı
^DB+Verb+Recip	Dönüşlü Çatı
^DB+Verb+Able	Yetkinlik Çatı
^DB+Verb+Repeat	Sürerlik Yardımcı Eylemi (-dur eki)
^DB+Verb+Hastily	Tezlik Yardımcı Eylemi (-ver eki)
^DB+Verb+EverSince	Sürerlik Yardımcı Eylemi (-gel eki)
^DB+Verb+Almost	(-yaz eki)
^DB+Verb+Stay	(-kal eki)
^DB+Verb+Start	Sürerlik Yardımcı Eylemi (-koy eki)

+Pos	Olumlu
+Neg	Olumsuz
+Past	Belirli Geçmiş Zaman
+Narr	Belirsiz Geçmiş Zaman
+Fut	Gelecek Zaman
+Aor	Geniş Zaman
+Pres	Şimdiki Zaman
+Desr	İstek Kipi
+Cond	Şart Kipi
+Neces	Gereklilik Kipi
+Opt	Dilek Kipi
+Imp	Emir Kipi
+Prog1	Şimdiki Zaman (-yor)
+Prog2	Şimdiki Zaman (-makta)
+Cop	Kesinlik / kuşku anlamı (-dır eki)
+AfterDoingSo	Bağlama Ulacı (-ıp eki)
+SinceDoingSo	Zaman Ulacı (-alı eki)
+AsLongAs	Zaman Ulacı (-dıkça eki)
+When	Zaman Ulacı (–ınca eki)
+ByDoingSo	Durum Ulacı (-arak eki)
+While	Durum Ulacı (-ken eki)
+AsIf	Kıyaslama Ulacı (-arcasına eki)
+WithoutHavingDoneSo	Durum Ulacı (-maksızın eki)
+With	İsimden Sıfat Yapan Yapım Eki (-lı eki)
+Without	İsimden Sıfat Yapan Yapım Eki (-sız eki)
+FitFor	İsimden Sıfat Yapan Yapım Eki (-lık eki)
+Agt	Yapım Eki (-çı eki)
+Dim	Küçültme Sıfatı Eki (-cik eki)
+Ness	Sıfattan İsim Yapan Yapım Eki (-lık eki)
+Become	İsimden Eylem Yapan Yapım Eki (-laş eki)
+Acquire	İsimden Eylem Yapan Yapım Eki (-lan eki)
+Zero	Ek gelmeden türetim olduğunu gösterir
+PCAbl	İlgeç, çıkma durumunda bir isimden sonra gelir
+PCAcc	İlgeç, belirtme durumunda bir isimden sonra gelir
+PCDat	İlgeç, yönelme durumunda bir isimden sonra gelir

+PCGen	İlgeç, tamlayan durumunda bir isimden sonra gelir
+PCIns	İlgeç, aracılık durumunda bir isimden sonra gelir
+PCNom	İlgeç, yalın durumda bir isimden sonra gelir

EK B – İNGİLİZCE TERİMLERİN TÜRKÇE KARŞILIKLARI

İngilizce	Türkçe
Ablative Case	Çıkma Durumu
Accusative Case	Belirtme Durumu
Agglutinative	Bitişken
Alignment	Hizalama
Ambiguity	Belirsizlik
Back-Off	Derece Düşürme
Beam-Search	Demetli Arama
Best First Search	İlk En İyiyle Arama
Bound Morpheme	Ek Biçem
Chunk	Grup
Chunking	Gruplama
Computer Aided Machine Translation	Bilgisayar Destekli Dil Çevirisi
Corpus	Derlem
Dative Case	Yönelme Durumu
Decoder	Çözücü
Depth-First Search	Derinliğine Arama
Derivation	Türetme
Derivational	Türetimsel
Direct Translation	Doğrudan Aktarım
Disambiguation	Belirsizlik Giderimi
Evaluation	Başarım Değerlendirmesi
Example-Based Machine Translation	Örnek Tabanlı Bilgisayarlı Çeviri
Finite State Machine	Sonlu Durumlu Makine
Finite State Recognizer	Sonlu Durumlu Tanıyıcı
Finite State Transducer	Sonlu Durumlu Dönüştürücü
Free Constituent Order Language	Öğelerin Yer Değiştirebildiği Dil
Free Morpheme	Serbest Biçem
Genitive Case	Tamlayan Durumu
Inflection	Çekim
Inflectional	Çekimli
Inflectional Group (IG)	Çekim Grubu (ÇG)
Information Extraction	Bilgi Çıkarımı

Information Retrieval	Bilgi Getirimi
Instrumental Case	Aracılık Durumu
Interlingua	Dilden Bağımsız Anlamsal Yapı
İnformation Acquisition	Bilgi Toplama
Lexical Ambiguity	Sözcüksel Belirsizlik
Lexical Representation	Yapısal Biçim
Lexicon	Alt Sözlük
Locative Case	Kalma Durumu
Machine Translation	Bilgisayarlı Metin Çevirisi
Maximum Likelihood Estimation	En Büyük Olabilirlik Kestirimi
Minimum Edit Distance	En Kısa Değişim Uzaklığı
Morfotactics	Morfotaktik
Morpheme	Biçem
Morphological Analyzer	Biçimbirimsel Çözümleyici
Morphological Generator	Biçimbirimsel Üretici
Morphology	Biçimbirim
Multi-Word Unit	Çoklu Sözcük Grubu
Mutual İntelligibility	Karşılıklı Anlaşılabilirlik
N-Best Lists	En İyi N Aday
Natural Language Processing	Doğal Dil İşleme
Noisy Channel Model	Gürültülü Kanal Modeli
Nominal	İsim Soylu
Noun Phrase	Ad Öbeği
Observation Probability	Gözlem Olasılıkları
Ortography	Yazım, Yazım Dili
Part-Of-Speech (POS)	Sözcük Türü
Phonetic	Sesbilgisel
Phrase	Sözcük Öbeği
Pos Tagger	Sözcük Türü Etiketleyici
Pragmatics	Bağlambilim
Precision	Kesinlik
Recall	Gerigetirim
Regular Expression	Düzenli İfade
Regular Language	Düzenli Dil
Semantics	Anlambilim
Smoothing	Yumuşatma
Statistical Language Model	İstatistiksel Dil Modeli
Sublanguage	Alt Dil
Surface Representation	Yüzeysel biçim
Syntax	Sözdizimi
Translation Model	Çeviri Modeli

Two-Level Morphology	İki-Düzeyli Biçimbirim
Verb Phrase	Eylem Öbeği
Verbal	Eylem Soylu
Formel	Biçimsel

ÖZGEÇMİŞ

Ahmet Cüneyd TANTUĞ, 1978 yılında Adana'da doğdu. 2000 yılında İstanbul Teknik Üniversitesi Otomatik Kontrol ve Bilgisayar Mühendisliği Bölümü'nden dereceyle mezun oldu. 2002 yılında İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Yüksek Lisans Programını bitirerek Yüksek Mühendis ünvanını aldıktan sonra gene aynı bölümde doktora çalışmalarına başladı.