

PHP a XML

Jiří Kosek

EDICE
PROFESSIONAL

GRADA

- Využití XML na webu a podpora XML v PHP5
- Čtení dokumentů pomocí SimpleXML, DOM, SAX a XMLReader
- XML schémata, XPath a XSLT
- Webové služby (SOAP, REST) a AJAX

Upozornění pro čtenáře a uživatele této knihy

Všechna práva vyhrazena. Žádná část této tištěné či elektronické knihy nesmí být reprodukována a šířena v papírové, elektronické či jiné podobě bez předchozího písemného souhlasu nakladatele. Neoprávněné užití této knihy bude **trestně stíháno**.

Používání elektronické verze knihy je umožněno jen osobě, která ji legálně nabyla a jen pro její osobní a vnitřní potřeby v rozsahu stanoveném autorským zákonem. Elektronická kniha je datový soubor, který lze užívat pouze v takové formě, v jaké jej lze stáhnout s portálu. Jakékoli neoprávněné užití elektronické knihy nebo její části, spočívající např. v kopírování, úpravách, prodeji, pronajímání, půjčování, sdělování veřejnosti nebo jakémkoliv druhu obchodování nebo neobchodního šíření je zakázáno! Zejména je zakázána jakákoli konverze datového souboru nebo extrakce části nebo celého textu, umisťování textu na servery, ze kterých je možno tento soubor dále stahovat, přitom není rozhodující, kdo takovéto sdílení umožnil. Je zakázáno sdělování údajů o uživatelském účtu jiným osobám, zasílání do technických prostředků, které chrání elektronickou knihu, případně omezují rozsah jejího užití. Uživatel také není oprávněn jakkoliv testovat, zkoušet či obcházet technické zabezpečení elektronické knihy.





Copyright © Grada Publishing, a.s.



Copyright © Grada Publishing, a.s.

Stručný obsah

Předmluva	13
Úvod	15
1. Syntaxe XML	17
2. Přehled podpory XML v PHP5	43
3. (Ne)podpora Unicode v PHP	67
4. SimpleXML	87
5. SAX	105
6. DOM	123
7. XMLReader	163
8. XPath	171
9. Schémata	195
10. Validace	265
11. XSLT	277
12. Webové služby	323
13. Zápis XML	345
Závěr	353
Použitá literatura	355
Rejstřík	357

Obsah

Předmluva	13
Úvod	15
1. Syntaxe XML	17
1.1 Elementy a struktura dokumentu	17
1.2 Datový model dokumentu	19
1.3 Atributy	20
1.4 Zápis vyhrazených znaků	21
1.5 Názvy elementů a atributů	22
1.6 Deklarace XML	22
1.7 Komentáře	23
1.8 Sekce CDATA	23
1.9 Instrukce pro zpracování	24
1.10 Automatická kontrola syntaxe	25
1.11 Jmenné prostory	25
1.12 Práce s bílými znaky	30
1.13 Skládání dokumentů	32
1.13.1 Entity	33
1.13.2 XInclude	35
1.14 Katalogové soubory	37
1.15 Speciální atributy	39
1.15.1 xml:lang	39
1.15.2 xml:space	39
1.15.3 xml:id	40
1.15.4 xml:base	40
2. Přehled podpory XML v PHP5	43
2.1 SimpleXML – jednoduše na věc	46
2.2 SAX – čteme pěkně popořádku	49
2.3 DOM – načteme to do paměti	55
2.4 XPath – rychle to najdeme	58

2.5	XSLT – jazyk budoucnosti	60
2.6	XMLReader – když se zamotáme do SAX	62
2.7	Webové služby	64
2.8	Závěr	66
3.	(Ne)podpora Unicode v PHP	67
3.1	Znakové sady, kódování a Unicode	67
3.1.1	Znaková sada	67
3.1.2	Kódování	68
3.1.3	Unicode	68
3.2	PHP a práce s řetězci	73
3.2.1	Ruční překódování	75
3.2.2	Knihovna mbstring	78
3.3	Další problémy	81
3.3.1	BOM a UTF-8	82
3.3.2	PHP a UTF-16	84
3.3.3	Unicode a porovnávání řetězců	84
4.	SimpleXML	87
4.1	Načtení dokumentu	87
4.2	Konfigurace parseru	88
4.3	Čtení hodnot	90
4.4	Práce se jmennými prostory	93
4.5	Smišený obsah	95
4.6	Využití XPathu	96
4.7	Modifikace dokumentu	97
4.8	Rozšířování třídy SimpleXMLElement	99
4.9	Příklady využití	101
5.	SAX	105
5.1	Události	106
5.1.1	Začátek elementu	106
5.1.2	Konec elementu	106
5.1.3	Znaková data	106
5.1.4	Instrukce pro zpracování	107
5.1.5	Začátek mapování prefixu jmenného prostoru	107
5.1.6	Konec mapování prefixu jmenného prostoru	107
5.1.7	Externí entita	108
5.1.8	Další události	108
5.2	Vytvoření parseru	109

5.3 Konfigurace parseru	109
5.4 Registrace obsluhy událostí	110
5.5 Čtení dat	110
5.6 Obsluha chyb	111
5.7 Zapouzdření obsluhy událostí do objektu	114
5.8 Přepínání obsluhy událostí	117
6. DOM	123
6.1 Objektová reprezentace dokumentu	123
6.2 Načtení dokumentu	124
6.3 Čtení dokumentu	126
6.3.1 Informace o uzlu	127
6.3.2 Pohyb po stromu	129
6.3.3 Výběr elementů na základě jména	131
6.3.4 Průchod celým dokumentem	133
6.3.5 Výběr elementu na základě ID	139
6.3.6 Čtení atributů	139
6.4 Modifikace dokumentu	141
6.4.1 Vytváření nových uzlů	141
6.4.2 Připojování a odpojování uzlů	142
6.4.3 Kopírování a klonování uzlů	147
6.4.4 Práce s atributy	149
6.4.5 Manipulace s textovými uzly	150
6.4.6 Vytvoření nového DOM stromu	151
6.4.7 Práce s fragmenty XML	151
6.4.8 Uložení dokumentu	153
6.5 Konfigurace parseru	153
6.6 Obsluha chyb	154
6.6.1 Ošetření chyb při načítání XML	155
6.6.2 Ošetření výjimek při práci s DOM stromem	156
6.7 Zpracování HTML	157
6.8 Rozšířování objektů DOM	160
6.9 Další možnosti DOM	161
7. XMLReader	163
7.1 Vytvoření a inicializace parseru	163
7.2 Konfigurace parseru	164
7.3 Čtení dat	165
7.3.1 Čtení obsahu elementů	166
7.3.2 Přeskočení elementu	167

7.3.3 Čtení atributů	168
8. XPath	171
8.1 Základní struktura výrazu	171
8.2 Datový model	172
8.3 Testování výrazů	174
8.4 Identifikátory osy	175
8.5 Testy uzlu	177
8.6 Zkrácený zápis	178
8.7 Predikáty	180
8.8 Příklady dotazů	181
8.9 Operátory	182
8.9.1 Matematické operátory	182
8.9.2 Relační operátory	183
8.9.3 Logické spojky	184
8.9.4 Sjednocení seznamů uzlů	184
8.10 Funkce	184
8.10.1 Funkce pro práci s uzly	185
8.10.2 Řetězcové funkce	186
8.10.3 Logické funkce	189
8.10.4 Funkce pro práci s čísly	189
8.11 Využití XPathu v DOM	190
8.12 Podpora XPath v dalších rozhraních	194
9. Schémata	195
9.1 Význam a historie schémat	195
9.1.1 Význam schémat	196
9.1.2 Historický vývoj jazyků pro popis schématu dokumentu	196
9.1.3 Srovnání nejpoužívanějších jazyků pro popis schématu dokumentu	198
9.2 DTD	202
9.2.1 Deklarace elementů	203
9.2.2 Deklarace atributů	205
9.2.3 Připojení DTD k dokumentu	207
9.2.4 Validace dokumentů oproti DTD	208
9.3 XML schémata	209
9.3.1 Datové typy	210
9.3.2 Jednoduché datové typy	210
9.3.3 Komplexní datové typy	217
9.3.4 Jmenné prostory	224
9.3.5 Připojení schématu k dokumentu a validace	225

9.4 RELAX NG	226
9.4.1 Základní vzory	228
9.4.2 Pokročilé vzory	233
9.4.3 Datové typy	241
9.4.4 Modularizace schématu	248
9.4.5 Jmenné prostory	250
9.4.6 Validace oproti RELAX NG schématu	252
9.5 Schematron	252
9.5.1 Validace pomocí XSLT	253
9.5.2 Vložení Schematronu do XML Schema	254
9.5.3 Vložení Schematronu do RELAX NG	255
9.5.4 Pokročilá validace	256
9.6 Best-practices pro návrh schémat	258
9.6.1 Elementy nebo atributy	258
9.6.2 Jmenné prostory	259
9.6.3 Názvy elementů a atributů	260
9.6.4 Defaultní a fixní hodnoty	261
9.6.5 Verzování schémat	261
9.6.6 Rozšířitelnost schémat	261
10. Validace	265
10.1 Validace pomocí rozhraní DOM	266
10.2 Validace pomocí rozhraní SimpleXML	268
10.3 Validace pomocí rozhraní XMLReader	268
10.4 Schematron	272
10.5 Praktické využití validace	273
11. XSLT	277
11.1 Základy XSLT	277
11.2 Cykly – iterativní zpracování	282
11.3 Řazení dat	285
11.4 Podmíněné zpracování	288
11.5 Generování výstupu	291
11.5.1 Generování elementů a atributů	292
11.5.2 Generování textového výstupu	292
11.5.3 Generování elementů a atributů s předem neznámým názvem	293
11.5.4 Generování speciálních konstrukcí	294
11.6 Zpracování dokumentů se jmennými prostory	294
11.7 Předávání parametrů	297
11.8 Podpora XSLT v PHP	300

11.9 Volání PHP funkcí z XSLT	305
11.10 Funkce přidané do XPathu	308
11.10.1 document()	308
11.10.2 key()	311
11.10.3 format-number()	311
11.10.4 current()	313
11.10.5 unparsed-entity-uri()	313
11.10.6 generate-id()	314
11.10.7 system-property()	317
11.10.8 element-available()	318
11.10.9 function-available()	318
11.11 Spouštění transformací na klientovi	318
12. Webové služby	323
12.1 Webové služby à la SOAP	324
12.1.1 Pod pokličkou SOAP	325
12.1.2 Pod pokličkou WSDL	326
12.1.3 PHP jako klient webové služby	330
12.1.4 Webová služba	333
12.2 Webové služby à la REST	335
12.3 AJAX	337
13. Zápis XML	345
13.1 Ruční generování XML	345
13.2 Generování pomocí DOM	348
13.3 Využití třídy XMLWriter	350
Závěr	353
Použitá literatura	355
Rejstřík	357

Předmluva

Když jsem před více než deseti lety psal předmluvu k dnes již legendární knize *PHP – tvorba interaktivních internetových aplikací* [11], slibil jsem v ní, že na doprovodný web knihy umístím informace o práci s formátem XML, které se do knihy již nevešly. Z časových důvodů k naplnění tohoto slibu nikdy nedošlo. Jako satisfakci proto přijměte tuto knihu. Její náplní je pouze XML a jeho použití v PHP.

Deset let je dlouhá doba, ale myslím, že čekání se vyplatilo. Podpora XML byla v PHP až do jeho verze 5.0 poměrně partyzánská. A teprve od verze 5.2 lze PHP považovat za jazyk, ve kterém se dá s XML rozumně pracovat.

O významu XML dnes již není potřeba nikoho přesvědčovat. Ať se nám to líbí nebo ne, XML je zkrátka všude a ve webových aplikacích je potřeba s tímto formátem pracovat. Ať už se jedná o importy a exporty dat, transformaci dat pro prezentační vrstvu nebo backend pro AJAXovou aplikaci. Cílem této knihy je naučit vás používat všechna existující rozhraní pro práci s technologiemi XML, která PHP nabízí. Popsán a vysvětlen je však i samotný jazyk XML, jeho syntaxe a navazující technologie jako XML schémata, dotazovací jazyk XPath a transformační jazyk XSLT. Pro pochopení výkladu tak není nutná žádná velká předchozí zkušenosť s XML – vše potřebné je průběžně vysvětleno.

V dnešní době začínají být papír a knihy považovány za příliš konzervativní médium. Asi jsem staromilec a mám tištěné knihy rád. Nicméně na adrese <http://www.kosek.cz/knihy/phpxml/> najdete další informace související s knihou – příklady ke stažení, opravy chyb apod. Máte-li ke knize nějaké připomínky, uvítám je na mojí emailové adresě <jirka@kosek.cz>.

Na vzniku knihy má zásluhu mnoho lidí. Nevyčerpatelnou trpělivost prokázali šéfredaktoři počítačové redakce Miroslav Lochman a Daniel Vrba, kteří vydrželi pět let čekat na dokončení knihy. Pokud v knize nebude příliš chyb, je to zásluha korektorky Zuzany Vrbové a redaktorky Evy Steinbachové. Největší dík však patří mé ženě Lence a dětem, kteří trpělivě snášely mé útěky k počítači při psaní knihy.

Přejí vám příjemné čtení knihy.

Jirka Kosek

Liberec, 10. dubna 2009

Úvod

Vývoj moderních webových aplikací klade na vývojáře vysoké nároky, je potřeba znát široké spektrum technologií. Počínaje jazyky HTML a CSS pro definici samotné stránky a jejího vzhledu, přes Javascript pro vytváření vysoce interaktivních aplikací, po nějaký serverový jazyk jako je PHP. Každá větší aplikace navíc potřebuje někam ukládat data, typicky do databáze. K tomu je potřeba znát principy protokolu HTTP a vědět, jak obcházet jeho limity. A aby toho nebylo málo, na mnoha místech se vývojář webové aplikace setká i s formátem XML.

Když XML v polovině 90. let minulého století vznikalo, původní smělé plány byly, že zcela nahradí jazyk HTML při doručování obsahu do prohlížeče. Tato myšlenka se však ukázala jako příliš revoluční a navíc problémy spojené s jazykem XHTML a jeho podporou v prohlížečích v očích mnoha webových vývojářů nevrhly na XML příliš růžové světlo. Nicméně technologie XML jsou dnes pevnou součástí mnoha webových technologií, formátů a protokolů, takže je potřeba práci s tímto formátem ovládat.

Kde se na webu s XML může vývojář setkat? Syntaxi XML využívají mnohé prezentativní formáty – počínaje jazykem XHTML, přes stále populárnější vektorový grafický formát SVG, až po jazyky pro definici uživatelského rozhraní v moderních RIA (Rich Internet Application) prostředích, jako je XAML v Silverlightu a MXML ve Flashi. Pokud tedy vaše skripty v PHP v minulosti generovaly převážně HTML kód, časem budou přicházet požadavky na dynamickou tvorbu modernějších, na XML založených, formátů.

XML dnes zcela dominuje na poli publikování metainformací. Jedná se například o formáty pro publikování přehledů nových článků, jako jsou RSS či Atom. Protože začleňování sémantiky ve strojově čitelné podobě přímo do webových stránek je stále v plenkách, mnoho vyhledávačů nabízí vlastní formáty, ve kterých jim můžete předávat informace vylepšující vyhledávání – například Google Sitemap nebo Google Base.

Další využití XML je pro komunikaci a předávání dat. XML se využívá jednak pro výměnu dat mezi backendy jednotlivých aplikací a dále pak v AJAXových aplikacích pro zaslání aktualizací dat do prohlížeče. „Enterprise“ aplikace pak pro samotnou komunikaci nevyužívají prosté XML, ale komplexnější mechanismus webových služeb.

Diverzita koncových zařízení používaných pro přístup k webu se také stále zvyšuje. Webové stránky se už neprohlížejí jen z klasického počítače, ale i z chytrých telefonů nebo různých PDA. Mnohé aplikace potřebují uspokojivě řešit možnost kvalitního tisku. Už nestačí vytvořit aplikaci, která výstupy generuje jen jako HTML. Pro jednotlivá koncová zařízení je potřeba generovat odlišné formáty výstupu a webovou aplikaci je potřeba obohatit o flexibilní prezentativní vrstvu. Pro vytvoření takové vrstvy lze využít i jazyk XML a stylové technologie jako XSL.

Výše uvedený výčet toho, kde se na webu můžeme setkat s XML, jistě není úplný. Pouze potvrzuje to, že webový vývojář se dnes neobejde bez znalosti tohoto formátu a práce s ním. Tato kniha vás naučí vše potřebné o formátu XML a navazujících technologiích a o tom, jak lze s tímto formátem pracovat v PHP.

První kapitola je určena zejména pro čtenáře, kteří ještě neznají formát XML. Seznámí se zde se syntaxí jazyka a naučí se ji kontrolovat.

Druhá kapitola pak stručně shrnuje a ukazuje, jaké možnosti pro práci s XML nabízí PHP. Je to ideální místo pro porovnání jednotlivých přístupů pro práci s XML. Nemusíte tak číst celou knihu, ale v této kapitole zjistíte, jaký způsob práce s XML je pro vás nevhodnější a ten si dále podrobnejší nastudujete v odpovídající samostatné kapitole.

Třetí kapitola přímo nesouvisí s XML, ale ukazuje, jak lze v PHP částečně obejít chybějící podporu znakové sady Unicode, kterou využívá i jazyk XML.

Následují čtyři kapitoly, které podrobně popisují jednotlivá rozhraní pro práci s XML – SimpleXML, SAX, DOM a XMLReader. Výběr vhodného rozhraní záleží na povaze dat, která čtete, a na tom, jak je potřebujete zpracovat.

Osmá kapitola seznamuje s dotazovacím jazykem XPath, který nabízí jednoduchou a zároveň mocnou metodu pro vyhledávání a výběr dat v dokumentech XML. Kromě samotného dotazovacího jazyka je zde samozřejmě popsáno, jak jej používat v kombinaci s rozhraními DOM a SimpleXML.

Další dvě kapitoly se věnují kontrole (validaci) dokumentů XML. Zvláště v otevřeném prostředí internetu je potřeba počítat s nejhorším a všechny vstupy do aplikace pečlivě kontrolovat. Pro dokumenty XML takovou kontrolu nabízejí schémata, která dokáží popsat povolenou strukturu a datové typy dokument XML. Devátá kapitola tak popisuje nejpoužívanější schémové jazyky a v desáté kapitole je pak ukázáno, jak pomocí nich prakticky v PHP kontrolovat data uložená v XML.

Jedenáctá kapitola vysvětuje základy jazyka XSLT a jeho použití v PHP. XSLT je nejhodnější prostředek pro transformace dokumentů XML do dalších formátů, včetně formátu HTML. Nalezne tak uplatnění například v prezentační vrstvě webové aplikace.

Následující dvanáctá kapitola se pak věnuje komunikaci mezi aplikacemi s využitím XML. Popsány jsou jak klasické webové služby, tak jednodušší mechanismy jako REST a AJAX.

Poslední třináctá kapitola pak ukazuje možnosti pro generování dokumentů XML na výstupu skriptu.

Kniha je zaměřena zejména na vysvětlení principů a na ukázky využití jednotlivých technologií a knihoven PHP. Ve většině případů jsou popsány všechny možnosti jednotlivých knihoven PHP. Nicméně kniha primárně neslouží jako referenční příručka, pro tyto účely je vhodné nahlížet i do dokumentace PHP na adresě <http://docs.php.net/manual/en/>.

Všechny příklady byly testovány s PHP ve verzi 5.2 a v současné době nic nenasvědčuje tomu, že by se v blízké době mělo v jazyce PHP měnit něco, co by způsobilo nefunkčnost skriptů. Většina použitých knihoven je standardně součástí PHP. Chcete-li používat XSLT, je potřeba do PHP přidat modul `php_xsl`, pro webové služby je zapotřebí modul `php_soap` a kapitola o Unicode využívá některé funkce z modulu `php_mbstring`.

Dlouhé řádky ve výpisech, které musely být rozdeleny, jsou označeny pomocí znaku `,►``.



Syntaxe XML

Chceme-li pracovat s dokumenty XML, musíme samozřejmě vědět, jak tyto dokumenty vypadají. V této kapitole se proto seznámíme se syntaxí jazyka XML a dalšími jeho rysy, které bychom měli znát. Znáte-li již XML dobře, a zajímá vás jen, jak se s ním pracuje v PHP, můžete tuto kapitolu směle přeskočit.

1.1 Elementy a struktura dokumentu

Každý XML dokument se skládá z *elementů*. Elementy se v textu vyznačují pomocí tzv. *tagů*. Většině elementů odpovídají dva tagy – počáteční a koncový.

```
<para>Toto je obsah elementu para.</para>
```

Ukázka obsahuje jeden element para. Jeho obsah je vyznačen pomocí tagů `<para>` (počáteční tag) a `</para>` (ukončovací tag). Jen na okraj poznamenejme, že výše uvedená ukázka je asi nejjednodušším dokumentem XML, který vůbec můžeme vytvořit.

Názvy tagů se zapisují mezi znaky `,<` a `,>`. Ukončovací tag má před svým názvem ještě znak `,/`, aby se odlišil od počátečního.

1.1 Elementy a struktura dokumentu



Obrázek 1.1: Základní části dokumentu XML

Některé elementy nemusejí mít žádný obsah. Můžeme je samozřejmě zapisovat tak, že za počátečním tagem uvedeme hned ten koncový.

```
<para>Toto je obsah elementu para.<br></br> A tohle také.</para>
```

Není to však příliš pohodlné, a proto můžeme v XML použít ještě jednu variantu tagu, která říká, že element nemá žádný obsah. Počáteční tag ukončíme dvojicí znaků ,/>' místo pouhého ,>' a koncový tag vynecháme.

```
<para>Toto je obsah elementu para.<br/> A tohle také.</para>
```

Každý dokument XML musí obsahovat pro všechny počáteční tagy odpovídající koncový tag, nebo musí být počáteční tag zapsán jako element s prázdným obsahem. Následující ukázky jsou ukázkami špatných dokumentů, které nevyhovují specifikaci XML.

```
<para>Toto je obsah elementu para.<br> A tohle také.</para>
```

Ukázka je chybná, neboť tag
 není ukončen.

```
<para>Toto je obsah elementu para.<br/> A tohle také.</oara>
```

1. Syntaxe XML