NEPARAMETRICKÉ TESTY

Neparametrický jednovýběrový

Jeden výběr jehož medián srovnáváme s nějakou hodnotou – Wilcoxonův jednovýběrový test

1) Máme data z družice Hipparcos pro deklinaci (obdoba zeměpisné šířky) pro pozici 2717 hvězd. Chceme testovat na hladině statistické významnosti 0,05, střední hodnota této deklinace je -47°. (dataset hip DE.sta**)**

H0: Medián deklinace je roven -47°. ($\tilde{x}$ =-47)

H1: Medián deklinace je staticky významně odlišný -47°. ($\tilde{x} \neq$ -47)

Krok A) Testování normality našeho výběru – p menší jak 0,05 -> Neparametrický test (Jinak by se dal použít parametrický)

Krok B) STATISTICA nám neumožňuje uskutečnit jednovýběrový Wilcoxonův test přímo. Ale pokud si uvědomíme, že se jedná vlastně o modifikaci párového testu, kde mediánem druhého výběru je právě číslo, s kterým srovnáváme medián našeho výběru, pak jsme schopni tento příklad vypočítat. Z H0 se tak stává ($\tilde{x}_1 - \tilde{x}_2$ =0, kde $\tilde{x}_2$ =-47**). Druhý výběr tak vytvoříme jednoduše tak, že vypočteme novou proměnnou jejíž všechny prvky budou rovny – 47.**

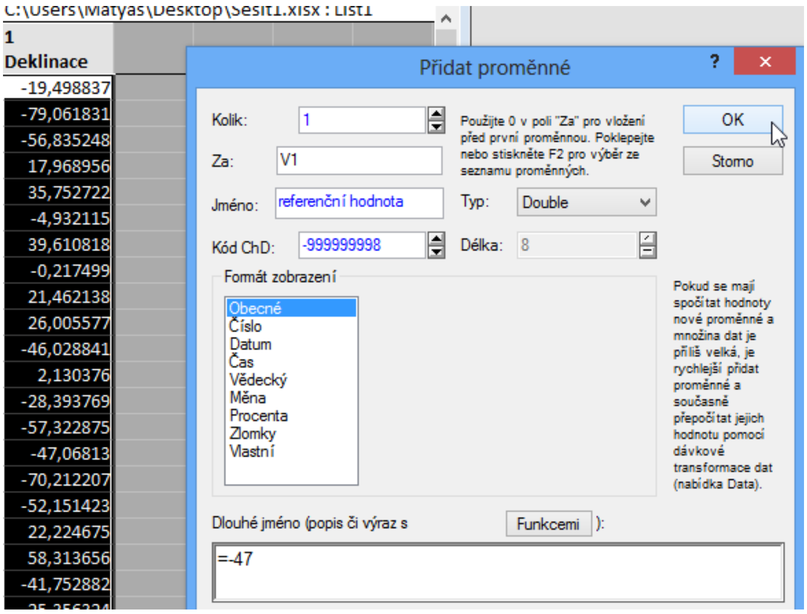

Krok C) Výpočet testové statistiky *Statistiky -> Neparametrická statistika -> Porovnání dvou závislých vzorků -> OK*

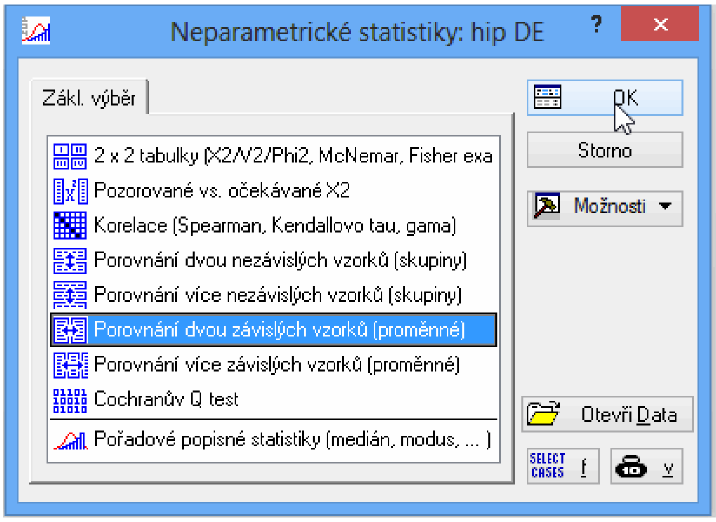

Jako proměnné vybereme naše dvě proměnné (*Deklinace* a *referenční hodnota*) a dáně *Wilcoxonův párový test…*

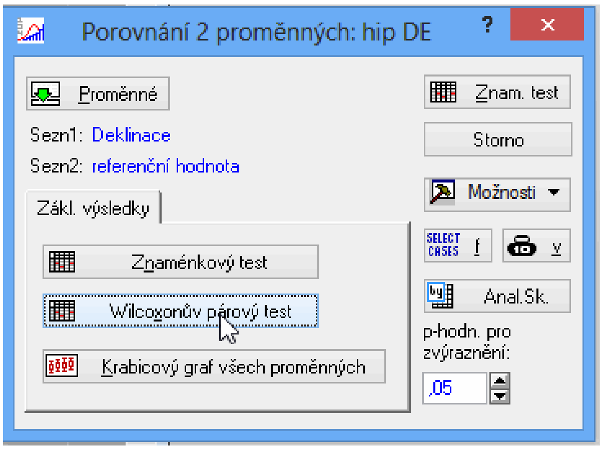

	Wilcoxonův párový test (hip DE) Označené testy jsou významné na hladině p <,05000			
Dvojice proměnných	Počet platných	T	Z	**p-hodn.**
Deklinace & referenční hodnota	2717	176548,0	40,82843	0,00

Z výsledků vidíme, že p-hodnota je menší než 0,05 – nulovou hypotézu o rovnosti mediánu našeho výběru k hodnotě -47 tedy **zamítáme.**

2) V různých částech České republiky bylo zjištěno procentuální zastoupení kuřáků nad 60 let. Zjistěte, zda je celkem v těchto regionech České republiky zastoupení kuřáků nad 60 let rovno 12 procentům. (populace_nad_60.sta**)**

Pokud se podíváte na normalitu těchto dat – pak zjistíte, že p-hodnota S-W testu je 0,07, což sice nezamítá nulovou hypotézu o normalitě, ale z důvodu malého vzorku a téměř dosažené hranice pro zamítnutí hypotézy by bylo vhodnější použít NEPARAMETRICKÝ test.

[p-hodnota 0,0499, Zamítáme nulovou hypotézu rovnosti mediánu našeho výběru a předpokládané hodnoty 12%]

3) Byl sledován zisk (v 1000 kč) jedné společnosti v 44 týdnech. Zjistěte zda byla střední hodnota zisku za tuto dobu rovna 175 000. (zisk.sta**)**

Opět normalita vychází, ale těsně nad hranici zamítnutí. (Opět lepší použít NEPARAMETRICKÝ test)

[p-hodnota menší jak 0,001, Zamítáme nulovou hypotézu rovnosti střední hodnoty zisku našeho výběru a předpokládané hodnoty 175]

NEPARAMETRICKÝ NEPÁROVÝ TEST

Srovnáváme hodnoty mediánů dvou na sebe nezávislých výběrů. Alespoň jeden výběr nemá splněný předpoklad normality dat.

1) Testujte na hladině statistické významnosti 0,05 rovnost šířky okvětních lístků u kosatců Setosy a Versicol. (kosatce.sta**)**

H0: Šířky okvětních lístků u Setosy a Versicolor jsou stejné. ($\tilde{x}_1 = \tilde{x}_2$)
H1: Šířky okvětních lístků u Setosy a Versicolor jsou odlišné. ($\tilde{x}_1 \neq \tilde{x}_2$)

Krok A) Data máme ve tvaru, kdy naměřené hodnoty šířky okvětních lístků máme rozděleny dle skupinové proměnné *IRISTYPE.* To znamená, že při testování normality jednotlivých výběrů musíme zapnout Analyzování dle skupin. (*viz parametrické testy-dvouvýběrový nepárový t-test*) –

Oba výběry nemají normální rozdělení – (normalita počítána *Statistiky->základní statistiky->tabulky četností->*záložka *Normalita*(Lilliefors a Shapiro-Wilk))

	IRISTYPE=SETOSA Testy normality (kosatce)				
Proměnná	N	max D	Lilliefors p	W	p
PETALWID: Width of Petals	50	0,348760	p < ,01	0,799764	0,000001

	IRISTYPE=VERSICOL Testy normality (kosatce)				
Proměnná	N	max D	Lilliefors p	W	p
PETALWID: Width of Petals	50	0,147699	p < ,01	0,947626	0,027278

Krok B) Výpočet statistiky – *Statistiky->Neparametrické statistiky -> Porovnání* *dvou nezávislých vzorků (skupiny)->OK*

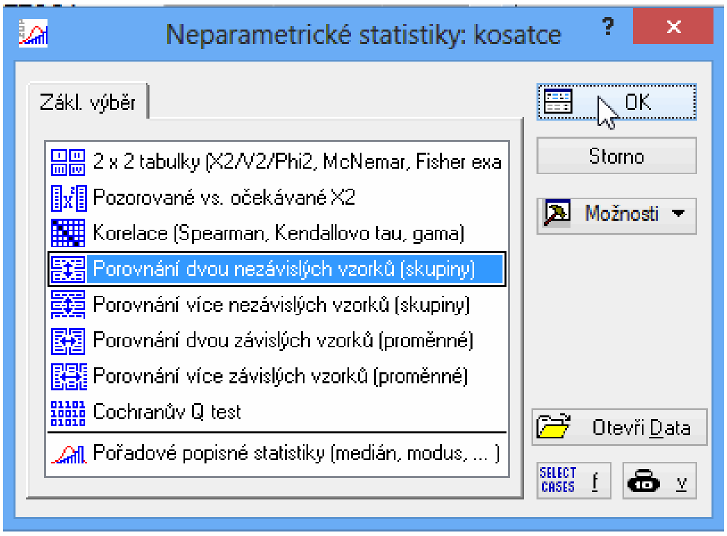

V případě, že by vstupní data byla ve formátu, že hodnoty okvětních lístků pro Setosu a Versicolor byly jednotlivé proměnné, pak si je musíme upravit do podoby jakou máme zde… tedy vytvořit skupinovou proměnnou

Vybereme proměnné…

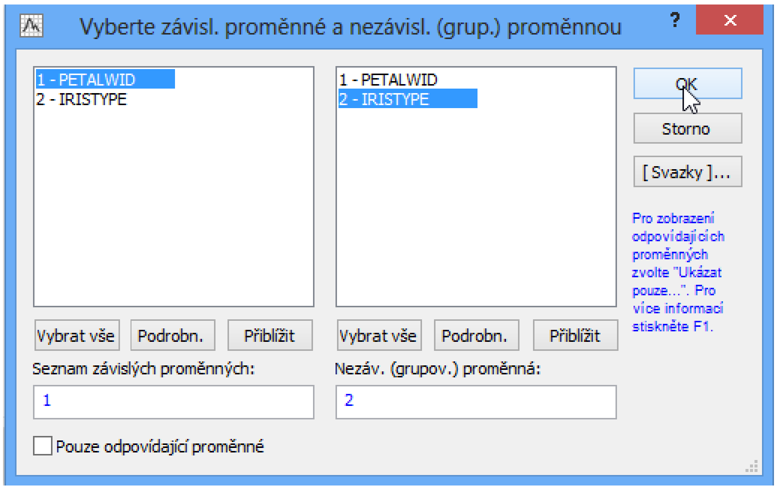

A vybereme Mann-Whitneyův U test

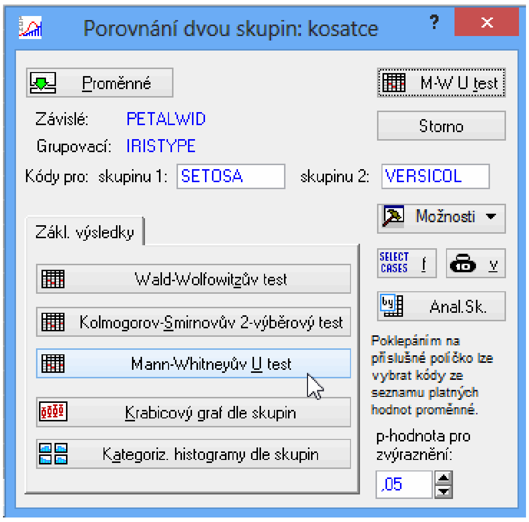

Výsledná tabulka:

Mann-Whitneyův U test (kosatce)
Dle proměn. IRISTYPE
Označené testy jsou významné na hladině p <,05000

Proměnná	Sčt poř. SETOSA	Sčt poř. VERSICOL	U	Z	p-hodn.	Z upravené	p-hodn.	N platn. SETOSA	N platn. VERSICOL	2*1str. přesné p
PETALWID	1275,000	3775,000	0,00	-8,61383	0,000000	-8,74227	0,000000	50	50	0,000000

Nyní se na základě velikosti vzorku (v tomto případě n=100) rozhodneme jakou p-hodnotu použijeme. Pokud je n>30 pak používáme asymptotickou p-hodnotu, pokud je n menší jak 30 pak používáme přesnou hodnotu.

Z výsledků je patrné, že zamítáme nulovou hypotézu.

2) Máme dvě odrůdy brambor a sledujeme jejich výnosnost na různých místech. Testujte na hladině významnosti 0,05, že výnosnost obou odrůd je stejná.(odrudy.sta)

- potřeba si vytvořit jednu skupinovou proměnnou a všechny výnosnosti dát pod sebe – vzniknou tak dvě proměnné o 18 případech…

[p – 0,161, nezamítáme nulovou hypotézu o stejné výnosnosti jednotlivých odrůd brambor.]

3) Máme dva typy kreditních karet Visa a M/E kartu. Na hladině významnosti 0,05 testujte, zda se v různých městech provede stejný počet plateb pomocí těchto dvou typů karet (počty v 1000) (kreditni_karty.sta).

Pozn.

- Pokud provedeme test normality tak vyjdou oba výběry normální, nicméně u jednoho vyjde p-hodnota blízká 0,05 (0,07) a z důvodu menšího n, bych doporučil dělat neparametrický test.

[p=0,252, Nezamítáme nulovou hypotézu o stejném používání M/E karty a Visa karty]

Neparametrický párový test

Testujeme, že se závislé proměnné neliší před a po nějaké události, popřípadě jiným způsobem měření.

Párovost lze zjistit pomocí korelací, viz. Parametrické párové testy.

1) Máme dvě měření křehkosti ocele (před zpracováním a po něm). Zjistěte, zda se statisticky významně liší. (ocel.sta**)**

Krok A) vytvoříme proměnnou diference obou měření…Zjistíme normalitu rozdílu před a po zpracování dat – viz. Parametrické párové testy. (p=0,03 – zamítáme normalitu diference dat)

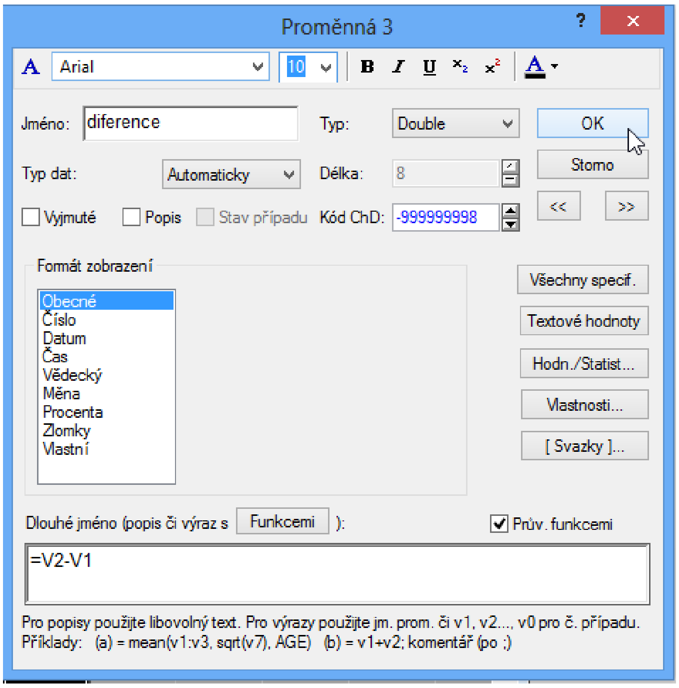

Krok B) Testování – *Statistiky->Neparametrické statistiky ->OK*

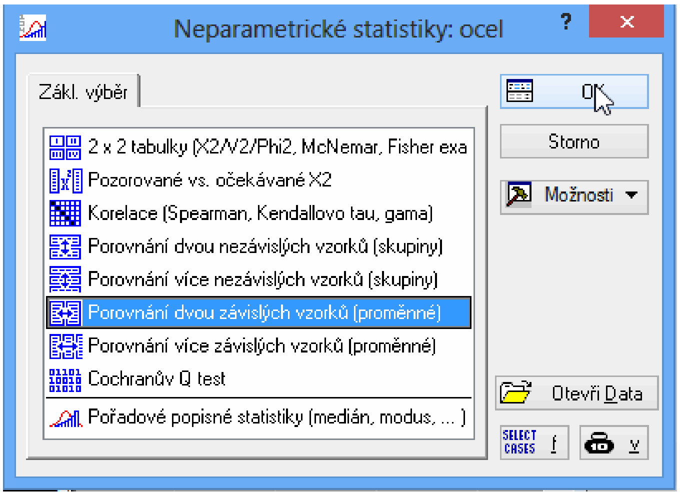

Vybereme proměnné a zvolíme *Wilcoxonův párový test* (větší síla – spíše na symetrická data..dá se posoudit dle tvaru histogramu) nebo *Znaménkový test* (*menší síla testu*)…v podstatě je na Vás jaký použijete – zde použijeme *Wilcoxonův test*

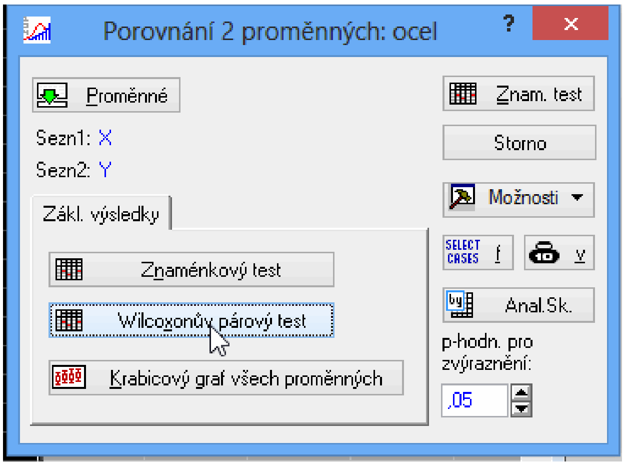

Výsledná tabulka:

	Wilcoxonův párový test (ocel) Označené testy jsou významné na hladině p <,05000			
Dvojice proměnných	Počet platných	T	Z	p-hodn.
X & Y	60	4,500000	6,702740	0,000000

Dle p-hodnoty vidíme, že zamítáme nulovou hypotézu o stejné křehkosti ocele před zpracováním a po něm.

2) Máme k dispozici nějakou hladinu jistého parametru v krvi (např. kreatininu)před operací a po operaci. Zjistěte zda se na hladině statistické významnosti 0,05 tyto dvě hladiny liší. (parametr_krve.sta)

[p- 0,017, Zamítáme nulovou hypotézu o rovnosti obsahu tohoto parametru v krvi před a po operaci]

3) Naměřili jsme hodnoty diet u jednotlivých druhů krys. Testujte, zda se jednotlivé diety liší (efektivita diety pro krysy.sta)

-Normalita – p=0,09 (Zde se asi dají použít oba druhy testů, jak parametrický tak neparametrický – ze cvičných důvodů použijeme neparametrický)

[p=0,056, Nezamítáme nulovou hypotézu o rovnosti jednotlivých typů diety.]