

## **Estymacja mechanicznych właściwości wapienia przy zastosowaniu analizy regresji i sztucznych sieci neuronowych**

### **Estimation of Mechanical Properties of Limestone Using Regression Analyses and ANN**

#### **1. Wstęp**

Wapień jest stosowany w produkcji cementu. Estymacja mechanicznych właściwości wapienia jest ważna dla przemysłu cementowego i betonowego. Kamień jest najstarszym budulcem stosowanym w budowie murów. Mury Jerycha (8000 lat temu) zbudowane jako mury obronne były najstarszymi archeologicznymi wykopaliskami. Kamień był szeroko wykorzystywany przez różne cywilizacje jako materiał budowlany przez tysiące lat (1). Nawet dzisiaj kamień jest stosowany jako materiał budowlany i okładzinowy w nowych budowlach (2). Z powodu swego znaczenia jako materiału budowlanego właściwości kamienia są przedmiotem wielu badań (2 – 7).

Określenie mechanicznych i fizycznych właściwości kamienia jest ważne dla analizy i odnowy murowanych budowli kamiennych, o znaczeniu historycznym (8, 9). Wytrzymałość muru jest wyznaczana przez wytrzymałość jego składników (10). Wytrzymałość kamienia wpływa na wytrzymałość muru kamiennego.

Jednakże pobieranie próbek z historycznych budowli do badań niszczących może być ograniczone ze względu na ochronę zabytków. Zastosowanie badań niszczących razem z ograniczeniem badań niszczących może pomóc badaczom w określeniu związków między wynikami z badań niszczących i nieniszczących. Związki te mogą być użyte do wyznaczania właściwości mechanicznych kamieni w różnych częściach budowli poprzez zastosowanie badań niszczących. Jeśli budowla jest zabytkiem pobór próbek kamienia do badań niszczących może być prawie niemożliwy. W tym przypadku zastosowanie badań niszczących oraz znanych z literatury związków dla podobnego rodzaju kamienia pozwoli na pierwsze przybliżenie właściwości mechanicznych.

Estymacja mechanicznych właściwości skał przy zastosowaniu badań niszczących jest także ważna w górnictwie, geoinżynierii i robotach ziemnych. Różni badacze pracują nad określeniem związków między badaniami niszczącymi i nieniszczącymi skał,

#### **1. Introduction**

Limestone is used in manufacturing of cement. The estimation of mechanical properties of limestone is important for cement and concrete industry. Stone is the oldest structural material used for masonry construction. Walls of Jericho (8000 B.B.) built as a military defence were the oldest archaeological excavations. Stone has been used extensively by different civilizations as a construction material for thousands of years (1). Even today, stone is used as a structural, facing and embezzlement material for new constructions (2). Due to its importance as a construction material, various researchers have worked on characterization of stone (2-7).

Determination of mechanical and physical properties of stone is important for analyses and rehabilitation of historical stone masonry structures (8, 9). The strength of masonry is determined by using the strength of its constituents (10). The strength of stone affects the strength of stone masonry.

However, stone sampling from a historical structure for destructive tests can be limited due to conservation purposes. The application of nondestructive tests along with limited destructive tests can help the researcher to develop correlations between nondestructive and destructive tests. These correlations can be used to estimate the mechanical properties of stones at different sections of the structure using nondestructive tests. If the structure is a historical monument, sampling of stone for destructive tests might be almost impossible. In that case, use of nondestructive tests along with the published correlations in the literature for similar stone type would yield a first estimation of the mechanical properties.

The estimation of mechanical properties of rocks using nondestructive techniques is also important for mining, geotechnical engineering and ground works. Different researchers have worked on developing relations between non-destructive and destructive tests for rocks as presented in Table 1. Relations between destructive test results are also important as some of the destructive tests are easier to apply while others need more expensive equipment and

jak to pokazano w tablicy 1. Związki między wynikami badań niszczących są także ważne, ponieważ niektóre badania niszczące są łatwiejsze do zastosowania podczas gdy inne wymagają droższego wyposażenia i są długotrwałe. Sachpazis (11) przedstawił zależności między modułem Younga (modułem sprężystości podłużnej E) i jednoosiową wytrzymałością na ściskanie. Zależności te są pokazane w tablicy 1.

time consuming. Sachpazis (11) presented a correlation between modulus of elasticity (E) and uniaxial compressive strength (UCS). These relations are given in Table 1.

In this study, mechanical properties of limestone obtained from a historical masonry structure were determined by laboratory tests. The mechanical properties were used in structural analyses and assessment of the historical structure (22). Regression analyses

Tablica 1 / Table 1

ZWIĄZKI MIĘDZY MECHANICZNYMI WŁAŚCIWOŚCIAMI SKAŁ  
CORRELATIONS BETWEEN MECHANICAL PROPERTIES OF ROCKS

References / Literatura	Correlations / Zależności	R <sup>2</sup>	Rock type Rodzaj skały	Range / Zakres	
				UCS	H
Yasar and Erdogan (2004) (12)	$UCS = 4.110 \cdot 10^{-6} \cdot H^{4.2917}$	0.79	Limestone, sandstone, basalt, marble	40-112	45-55
Kahraman (2001) (13)	$UCS = 6.97 \cdot e^{0.01Hnp}$ $UCS = 9.95 \cdot V^{1.21}$	0.60 0.69	Carbonates	4-153	15-70
Sachpazis (1990) (14)	$UCS = 4.29 \cdot H - 67.52$ $E = 1.94 \cdot H - 33.93$ $E = 0.3752 \cdot UCS + 4.428$	0.92 0.77 0.81	33 different carbonates	22-311	16-60
O'Rourke (1989) (15)	$UCS = 4.85 \cdot H - 76.18$	0.59	Limestone, sandstone, siltstone, anhydride	14-215	19-52
Çobanoglu and Celik (2008) (16)	$UCS = 6.59 \cdot H - 212.63$ $UCS = 56.71 \cdot V - 192.93$	0.64 0.67	Limestone, sandstone, cement mortar	40-120	40-50
Yagiz (2009) (17)	$UCS = 0.0028 \cdot H^{2.584}$ $E = 1.233 \cdot H - 17.8$	0.85 0.72	Limestone, schist	31-127	36-60
Aydin and Basu (2005) (18)	$UCS = 1.45 \cdot e^{0.07H}$ $E = 1.04 \cdot e^{0.06H}$	0.84 0.82	Granite	6-196	20-65
Yilmaz and Sendir (2002) (19)	$UCS = 2.27 \cdot e^{0.06H}$ $E = 3.15 \cdot e^{0.05H}$	0.96 0.90	Gypsum	15-30	30-44
Tugrul and Zarif (1999) (20)	$UCS = 8.36 \cdot H - 416$ $TS = 0.15 \cdot UCS - 0.73$ $E = 0.35 \cdot UCS - 12$	0.76 0.85 0.88	Granite	109-193	64-72
Katz et al. (2000) (21)	$UCS = 2.21 \cdot e^{0.07Hn}$ $E = 1.3 \cdot 10^{-4} \cdot Hn^{3.09}$	0.96 0.99	Limestone, sandstone, Syenite, granite	11-259	24-73

UCS (MPa): Uniaxial compressive strength / Jednoosiowa wytrzymałość na ściskanie; E (GPa): Modulus of elasticity / Moduł Younga; H and/i Hn: Schmidt hammer rebound values for L type and N type hammers, respectively/wartości elastyczności odbicia młotka Schmidta odpowiednio dla typu L i N; ρ: density / gęstość (gm/cm<sup>3</sup>); V: wave velocity/szybkość fali (km/s), TS (MPa): Tensile strength / wytrzymałość na rozciąganie. R<sup>2</sup>: Coefficient of determination / współczynnik determinacji.

W niniejszych badaniach mechaniczne właściwości kamienia wapiennego uzyskanego z zabytkowych murowanych budowli określono w badaniach laboratoryjnych. Właściwości mechaniczne wykorzystano w analizie strukturalnej i ocenie zabytkowej budowli (22). Analizę regresji zastosowano do badań związków między mechanicznymi właściwościami wapienia. Po raz pierwszy pewnym wkładem do bieżącej literatury przedmiotu jest zastosowanie sztucznych sieci neuronowych (SSN) do określenia właściwości mechanicznych kamienia wapiennego. Podano oddzielne ciągi danych do treningu i oceny jego wyników w zakresie analizy regresji co w opinii autorów zostało po raz pierwszy opublikowane. Również pierwszy raz zastosowano opracowane modele regresji i sztucznych sieci neuronowych do przewidywania mechanicznych właściwości kamieni pochodzących z zabytkowych budowli murowanych. Niektóre modele regresji opracowane w niniejszych badaniach są pierwszy raz opublikowane dla

were used to develop correlations between mechanical properties of limestone. As a contribution to the current literature, Artificial Neural Network (ANN) was performed in determining the mechanical properties of limestone for the first time in the literature. The data is separated in training and testing sets, which were used to train and test both ANN and regression analyses. The use of separate training and testing sets for the regression analyses has been applied for the first time in the literature to the best knowledge of the authors. Development of regression and ANN models to predict mechanical properties of stones obtained from historical masonry structure is applied for the first time. Some of the regression models developed in this work have been published for the first time in the literature for limestone (relations between tensile strength and wave velocity, tensile strength and porosity, wave velocity and porosity). The ANN and regression analyses were compared to the existing correlations available in the literature. The

kamienia wapiennego (związki między wytrzymałością na rozciąganie i szybkością fali, wytrzymałością na rozciąganie a porowatością, szybkością fali a porowatością). Wyniki modeli uzyskanych przy zastosowaniu sztucznych sieci neuronowych i regresji były porównane z istniejącymi związkami dostępnymi w literaturze. Model regresji i sztuczne sieci neuronowe charakteryzują się wystarczającym dopasowaniem w estymacji mechanicznych właściwości kamienia wapiennego.

Kamień wapienny powszechnie występuje w Urli i Izmirze w Turcji, gdzie przeprowadzono badania. Był stosowany w historycznych budowlach, jak również stosuje się go w nowych budowlach, jako materiał budowlany. Modele regresji z niniejszych badań mogą być używane przez badaczy pracujących na historycznych i starożytnych budowlach w tym rejonie. Jedno z dwunastu starożytnych miast Ioni, Klazomenai, jest bardzo bliskie budowli, z której pobrano kamienie (23, 24). Klazomenai było wspomniane przez sławnego historyka Herodotusa Halikarnasusa (484-425 p.n.e.) (25). Druga najstarsza w świecie fabryka oliwy jest w Klazomenai. Fabryka jest zbudowana z wapienia. Kamienie starożytnego miasta Klazomenai i starożytnej fabryki oliwy są podobne do kamieni analizowanych w niniejszej pracy. Ze względu na ochronę zabytków jest niemożliwym pobranie kamieni ze starożytnego miasta lub fabryki do przeprowadzenia badań. Badacze mogą stosować modele z niniejszej pracy związane z właściwościami mechanicznymi kamieni wapiennych starożytnego Klazomenai i starożytnej fabryki oliwy.

Modele regresji opracowane w niniejszych badaniach mogą także być wykorzystywane przez naukowców i inżynierów, którzy pracują w przemyśle cementowym i betonowym stosując wapienie o podobnych właściwościach mechanicznych.

## 2. Część doświadczalna

Wapienie były pozyskane z Urla Kamanlı Mosque, w Urli, Izmir, Turcja (rysunek 1). Budowla jest zlokalizowana na zachodnim wybrzeżu Turcji, w okręgu Izmir, mieście Urla, które leży na wybrze-



Rys. 1. Lokalizacja budowli, gdzie pozyskano próbki wapienia

Fig. 1. The location of the structure where the limestone samples were obtained

regression model and ANN are having satisfactory performances in estimating the mechanical properties of limestone. Limestone is abundant in Urla, Izmir, Turkey where the study was conducted. It has been used in historical structures as well as in new structures as a construction material.

The regression models in this study can be used by researchers working on historical and ancient structures in the region. One of the twelve ancient Ion cities, Klazomenai, is very close to the structure which the stones were taken (23, 24). Klazomenai was cited by the famous historian Herodotus Halikarnasus (484-425 BC) (25). The 2nd oldest olive oil factory of the world is in Klazomenai. The stones of the ancient factory are limestone. The stones of Klazomenai ancient city and ancient olive oil factory are similar to the ones analyzed in this work. Due to conservation purposes, it is impossible to remove the stones of the ancient city or ancient factory for testing. The researchers can use the models in this work to relate the mechanical properties of limestone for the ancient city Klazomenai and ancient olive oil factory. The regression models developed in this work can also be used by researchers and field engineers that work with limestone having similar mechanical properties in cement and concrete industry.

## 2. Experimental Work


The limestones were obtained from Urla Kamanlı Mosque, in Urla, Izmir, Turkey (Fig. 1). The structure is located on the west coast of



Rys. 2. (a) Widok północnej elewacji budowli. (b) Zachodnia i południowa elewacja, z których pobrano kamienie (fotografie wykonane po przywróceniu do użytkowania)

Fig. 2. (a) The north elevation view of the structure (b) The west and south elevation where stones were taken (Photos taken after restoration)

żu Morza Aegen, co pokazano na rysunku 1. Budowla jest częścią zespołu budowli Yahşi Bey Complex, który zawiera łaźnię turecką, grobowiec, dwie fontanny i szkołę podstawową. Nie istnieją żadne dokumenty dotyczące daty budowy i budowniczych. Stosując metody porównawcze elementów architektonicznych znanych z historii sztuki stwierdzono, że budowla pochodzi z okresu między wczesnym wiekiem czternastym, a połową wieku piętnastego (26). Budowla ma plan kwadratu o wymiarach 10 m×10 m ze ścianami o grubości 110 cm. Wysokość budowli jest równa 12,66 m. Widok elewacji północnej jest pokazany na rysunku 2a, a zachodnia i południowa elewacja są pokazane na rysunku 2b. Plan budowli jest przedstawiony na rysunku 3. Ściany są kamiennym murem z wapienia i grubymi spoinami w murze. Łuki okienne i kopuła są murem ceglany z grubymi spoinami w murze. Trompy, które są także murem ceglany, zastosowano w przejściu ze ścian do kopuły, na narożach. Budowla nie była wykorzystywana przez długi okres czasu i została przywrócona do użytkowania po wykonaniu niniejszych badań.



Rys. 3. Plan budowli i lokalizacje, z których pobrano kamienie

Fig. 3. The plan of the structure and the locations of the stones taken

Dwa kamienie z części południowej (South1: St1 i South1: St2) oraz dwa kamienie z części zachodniej (West1: W1 and West2: W2) pozyskano z budowli. Lokalizacje kamieni są pokazane na rysunku 2b i 3. Cylindryczne próbki rdzeniowe o średnicy  $D = 54$  mm były pobrane wiertłem rozmiaru NX (27). Czoła próbek zostały odcięte i próbki były polerowane przy użyciu pyłu żelaznego do uzyskania gładkich i równoległych powierzchni. Wysokości próbek zostały dobrane zgodnie z wymaganiami ISRM do pomiarów jednoosiowego ściskania i rozciągania (27).

Skład fazowy zawierał kalcyt  $\text{CaCO}_3$  oznaczony rentgenograficznie, przy zastosowaniu dyfraktometru Philipsa z oprogramowaniem wspomagającym do analizy X-Pert X-Ray diffraction (XRD) co jest pokazane na rysunku 4.

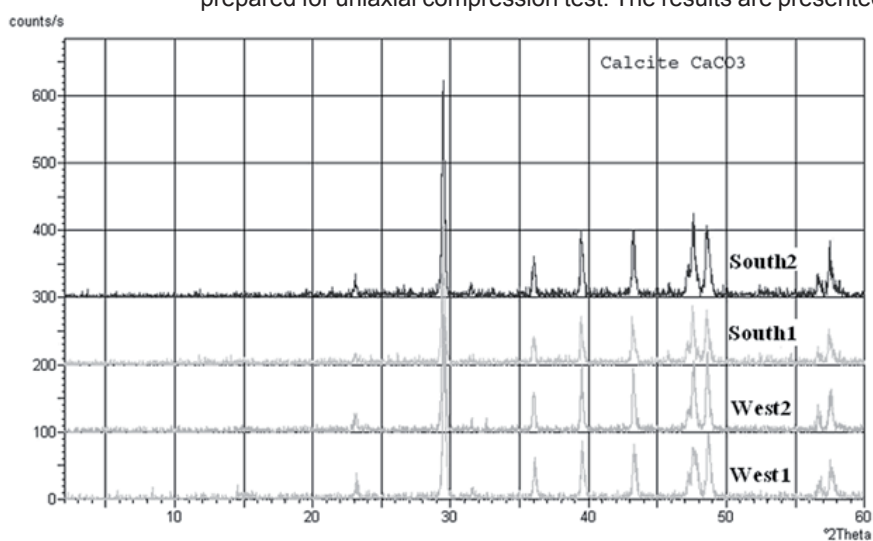
Turkey, in the city of Izmir, town of Urla, which is on the shore of Aegen Sea as can be seen in Fig. 1. The structure is a member of a group of structures, Yahşi Bey Complex, which contains a Turkish Bath, a tomb, two fountains and a primary school. There is not any written document about the construction date and constructors. Using the comparative methods of architectural elements in light of art history, it is concluded that the structure date back to an era between early 14th century to mid 15th century (26). The structure has a square plan having dimensions of 10 m×10 m with a wall thickness of 110 cm. The height of the structure is 12.66 m. The north elevation view of the structure is in Fig. 2a and west and south elevations are in Fig. 2b. The plan of the structure is presented in Fig. 3. The walls are stone masonry with limestone and thick mortar joints. The window arches and dome are brick masonry with thick mortar joints. Tromps which are also brick masonry, were used in the transition from walls to dome on the corners. The structure had not been used for a long time and it was restored after this study.

Two stones from south section (South1: St1 and South1: St2) and two stones from west section (West1: W1 and West2: W2) were obtained from the structure. The locations of the stones are presented in Fig. 2b and Fig. 3. NX sized (27) cylinder core samples having diameters of  $D = 54$  mm were drilled. The heads of the samples were cut off and polished by iron dust to have smooth and parallel surfaces. The sample heights were adjusted according to ISRM for uniaxial compression and split tensile tests (27).

The chemical composition of the stones were determined to be  $\text{CaCO}_3$  by use of Philips X-Pert X-Ray diffraction (XRD) as seen in Fig. 4.

### 2.1. Tests on Core Samples for Uniaxial Compression Test

Schmidt hardness ( $H$ ), ultrasonic wave velocity ( $V$ ) and uniaxial compression strength ( $UCS$ ) tests were applied on core samples prepared for uniaxial compression test. The results are presented



Rys. 4. Dyfraktogram rentgenowski próbek kamienia wapiennego (oś x: kąt XRD; oś y: zliczenia/s)

Fig. 4. The XRD patterns of stone samples (x-axis: XRD angle; y-axis: counts/s)

## 2.1. Jednoosiowa próba ściskania próbek rdzeniowych

Badania twardości Schmidta ( $H$ ), ultradźwiękowej szybkości fali ( $V$ ) i jednoosiowej wytrzymałości na ściskanie (UCS) zostały przeprowadzone na próbkach rdzeniowych przygotowanych do jednoosiowej próby ściskania. Wyniki badań przedstawiono w tabelicy 2. W tabelicy 2 oznaczenie St1-15 odnosi się do piętnastej próbki rdzeniowej kamienia wapiennego pobranej z południowej próbki kamienia wapiennego ST1. Analogicznie oznaczone są pozostałe próbki.

Młotek Schmidta jest powszechnie używany w próbach polowych i laboratoryjnych do badania betonu i kamienia. Metoda została opracowana do pomiaru wytrzymałości betonu przez Ernsta Schmidta w 1940 r. Badanie to jest dla kamienia stosowane od 1960 r. Młotek Schmidta ma możliwość użycia różnych energii uderzenia 0.74 Nm (typ L) i 2.1 Nm (typ N) (12). Energia jest magazynowana w sprężynie przez dociśnięcie ruchomego bijaka do powierzchni kamienia. Przy granicznej wartości energii sprężyna uwalnia się i uderza masą uderzeniową o bijak. Odskok masy uderzeniowej jest miarą twardości Schmidta ( $H$ ) (27).

W niniejszych badaniach pomiar twardości młotkiem Schmidta wykonywano na rdzeniowych próbkach cylindrycznych przy zastosowaniu przyrządu typu L, o energii uderzenia 0.74 Nm. Stalowa kołyska o rowku cylindrycznym, którego promień był taki sam jak promień rdzenia, była zastosowana do zamocowania próbki rdzeniowej. Badanie zostało wykonane zgodnie z ISRM (1981) (27), a wyniki są przedstawione w tabelicy 2.

Przyrząd do badania ultradźwiękowego typu Pundit (CNS Farnell Electronics) zastosowano do pomiaru szybkości fali. W badaniu tym impuls fali ultradźwiękowej wytwarzany w transmitterze przechodzi przez rdzeń kamienny i jest odbierany przez odbiornik. Mierzony jest czas potrzebny na przejście impulsu fali ultradźwiękowej przez próbkę. Szybkość fali ( $V$ ) jest obliczana na podstawie odległości między próbnikami (wysokość rdzenia cylindrycznego) i jest zestawiona w tabelicy 2.

Jednoosiowa próba ściskania została przeprowadzona na kamiennych próbkach rdzeniowych przy zastosowaniu maszyny wytrzymałościowej do wyznaczenia jednoosiowej wytrzymałości na ściskanie. Zakres szybkości pomiaru i inne warunki badania były zgodne z ISRM (1981) (27). Moduł sprężystości podłużnej ( $E$ ) został wyznaczony z krzywych rozciągania, uzyskanych podczas badań (27).

## 2.2. Badania wytrzymałości na rozciąganie przy rozłupywaniu na próbkach rdzeniowych

Badania szybkości fali ultradźwiękowej i porowatości ( $p$ ) były wykonane na rdzeniach kamiennych przygotowanych do badań wytrzymałości na rozciąganie przy rozłupywaniu. Wyniki badań są przedstawione w tabelicy 3. W tabelicy 3 oznaczenie St1-t12 odnosi się do dwunastej kamienną próbkę rdzeniową pobraną z południowej próbki kamienia St1 w celu przeprowadzenia badania wytrzymałości na rozciąganie przy rozłupywaniu. Pozostałe oznaczenia są analogiczne. Badanie szybkości fali ultradźwiękowej prze-

in table 2. In table 2, the St1-15 stands for 15th stone core sample drilled out from south stone sample St1. The other core names are given analogously.

Tablica 2 / Table 2

WYNIKI BADAŃ JEDNOOSIOWEGO ŚCISKANIA PRÓBEK RDZENIOWYCH

TEST RESULTS OF UNIAXIAL COMPRESSION TEST CORE SAMPLES

No.	Name	Schmidt Hardness $H$	$V$ , km/s	UCS, MPa	$E$ , GPa
1	St1-1	33	3,20	62	8,57
2	St1-2	33	3,36	74	9,82
3	St1-3	28	3,36	70	9,33
4	St1-4	31	3,26	68	9,33
5	St1-5	31	3,26	69	9,93
6	St1-6	30	3,36	69	10,00
7	St1-7	29	3,15	63	8,73
8	St1-8	29	3,30	60	9,58
9	St1-9	30	3,16	64	9,10
10	St1-10	30	3,15	48	7,78
11	St1-11	30	3,33	74	10,39
12	St1-12	29	3,21	67	9,57
13	St1-13	32	3,30	68	10,29
14	St1-14	32	3,42	67	9,84
15	St1-15	32	3,21	68	9,97
16	St1-16	32	3,40	73	10,27
17	St1-17	31	3,39	76	10,59
18	St2-1	32	3,57	72	11,22
19	St2-2	33	3,37	73	9,57
20	St2-3	33	3,23	79	9,70
21	St2-4	33	3,26	63	8,06
22	St2-5	30	3,56	84	11,09
23	St2-6	31	3,63	88	12,54
24	St2-7	33	3,31	52	8,44
25	St2-8	30	3,49	63	11,09
26	St2-9	33	3,45	70	9,07
27	St2-10	32	3,31	82	9,19
28	W1-1	39	5,21	157	30,55
29	W1-2	40	5,18	153	32,20
30	W1-3	39	5,20	107	29,91
31	W1-4	40	5,18	135	30,92
32	W1-5	39	5,16	131	NA
33	W1-6	40	5,27	135	NA
34	W2-1	36	5,67	107	31,19
35	W2-2	39	5,58	97	27,58
36	W2-3	39	5,53	165	NA
37	W2-4	39	5,59	143	NA

NA: Data not available / Dane niedostępne.

przewodzone na kamiennych próbkach rdzeniowych przygotowanych do próby jednoosiowego ściskania. Porowatość ( $p$ ) może być wykorzystana do określenia rozmiaru niektórych rodzajów zniszczenia kamienia i jakości zabiegu impregnacji. Badanie porowatości przeprowadzono zgodnie z RILEM (1980) (28). Próbki były suszone w temperaturze  $60 \pm 5^\circ\text{C}$  do uzyskania stałej masy ( $W_{dry}$ ). Próbki przechowywano w wodzie przy podciśnieniu i wówczas ważono w wodzie ( $W_{arc}$ ). Próbki wycierano stosując wilgotną tkaninę i mierzono masy próbek nasyconych wodą ( $W_{wet}$ ). Porowatość obliczano z równania [1]. Badanie porowatości przeprowadzono dla 31 z 40 próbek wymienionych w tabelicy 3.

$$p = \frac{W_{wet} - W_{dry}}{W_{wet} - W_{arc}} \times 100 \quad [1]$$

Wytrzymałość na rozciąganie ( $TS$ ) kamienia wyznaczano z próby rozciągania przy rozłupywaniu zgodnie z ISRM (1981) (27). Próbki rdzeniowe obciążano wzdłuż średnicy i zapisywano siłę rozrywającą ( $F$ ). Wytrzymałość na rozciąganie jest wyliczana ze wzoru:

$$TS = 0.636 \times \frac{F}{Dt} \quad [2]$$

gdzie:  $F$  jest siłą rozrywającą,  $D$  średnicą,  $t$  grubością próbki rdzeniowej,  $TS$  jest wyrażane w MPa. Wyniki zebrano w tabelicy 3. Dwie próby odrzucono z powodu wczesnego zniszczenia próbki podczas obciążania wstępnego.

### 3. Analiza regresji i sztuczne sieci neuronowe (SSN)

Celem zastosowania analizy regresji i sztucznych sieci neuronowych w niniejszej pracy była estymacja ważnych, mechanicznych właściwości wapienia przy użyciu jak najmniejszej liczby danych wejściowych. W ten sposób można oszacować właściwości mechaniczne po przeprowadzeniu tylko jednego eksperymentu, a nie kilku różnych doświadczeń. Z tego względu sprawdzono przydatność analizy regresji z jedną zmienną objaśniającą i sztucznej sieci neuronowej z pojedynczym sygnałem wejściowym do opracowania stosownych wzorów.

Analizę regresji stosowano do badania zależności między różnymi właściwościami mechanicznymi wapienia. Stosowano regresję liniową, wielomianową, logarytmiczną, potęgową lub wykładniczą dla wszystkich badanych zależności. Rodzaj regresji dający największą wartość współczynnika determinacji ( $R^2$ ) wybrano jako regresję definiującą korelację między właściwościami mechanicznymi.

SSN można zastosować do modelowania problemów nieliniowych z wieloma zmiennymi przeprowadzając szereg równoległych obliczeń, w przeciwieństwie do klasycznych modeli matematycznych opierających się na obliczaniu krok po kroku funkcji matematycznych i logicznych (29). SSN zastosowano w geotechnice i inżynierii skalnej jako narzędzie prognostyczne (30-36). Sztuczna sieć neuronowa składa się z warstwy wejściowej warstwy/warstw ukrytych

Schmidt hammer test is widely used in field and in the laboratory conditions for testing concrete and stone. The test was developed for measuring the strength of concrete by Ernst Schmidt in 1940s. The test has been used for stone since 1960s. Schmidt hammer is available with different impact energies of 0.74 Nm for L type and 2.1 Nm for N type (12). Energy is stored in a spring by pressing the plunger of the hammer on the stone surface. At a definite energy level, the spring releases and impacts a mass against the plunger. The rebound of the mass is measured as the Schmidt hardness ( $H$ ) (27).

In this study, Schmidt rebound hardness test was applied on stone core samples using an L type Schmidt hammer having an impact energy of 0.74 Nm. A steel cradle having a cylindrical slot of the same radius of the core was used to hold the core sample. The test was conducted following ISRM (1981) (27) and the results are presented in Table 2.

A Pundit type equipment (CNS Farnell Electronic's) was used to measure the wave velocity. In this test, ultrasonic pulse waves which were created by the transmitter, passed through the stone core and were received by receiver. The time needed for the ultrasonic pulse waves to pass the sample was measured. The velocity of the wave ( $V$ ) was calculated using the distance between the probes (the height of the cylinder core) and presented in Table 2.

Uniaxial compression test was applied on stone core samples using mechanical testing machine to determine uniaxial compressive strength ( $UCS$ ). The loading rate and other experimental procedures were adjusted according to ISRM (1981) (27). The modulus of elasticity ( $E$ ) was determined from the stress-strain curves obtained from the test (27).

#### 2.2. Tests on Core Samples For Split Tensile Test

The ultrasonic wave velocity and porosity ( $p$ ) tests were applied on the stone cores prepared for split tensile test. The results are presented in Table 3. In Table 3, the St1-t12 stands for 12th stone core sample drilled out from south stone sample St1 for split tensile test. The other core names are given in a similar way. The ultrasonic wave velocity test was conducted as defined for uniaxial compression test stone core samples. Porosity ( $p$ ) can be used to determine the extent of some types of stone decay and the success of an impregnation treatment. Porosity test was applied following RILEM (1980) (28). The samples were dried at  $60 \pm 5^\circ\text{C}$  until reaching constant mass ( $W_{dry}$ ). The samples were maintained in water under vacuum and then weighed in water ( $W_{arc}$ ). The samples were wiped with a damp cloth and weights of the samples saturated with water were measured ( $W_{wet}$ ). The porosity was determined using equation [1]. The porosity test was applied to 31 out of 40 core samples in Table 3.

$$p = \frac{W_{wet} - W_{dry}}{W_{wet} - W_{arc}} \times 100 \quad [1]$$

The tensile strength ( $TS$ ) of the stone was determined by split tensile test as defined by ISRM (1981) (27). The core samples

Tablica 3/ Table 3

WYNIKI BADAŃ PRÓBY ROZCIĄGANIA ROZSZCZEPIAJĄCEGO PRÓBK  
KI RDZENIOWE

TEST RESULTS OF SPLIT TENSILE TEST CORE SAMPLES

No.	Name	V, km/sec	% porosity, p	Tensile strength TS, MPa
1	St1-t1	2,97	NA	4,94
2	St1-t2	2,73	NA	4,66
3	St1-t3	3,03	15,1	6,79
4	St1-t4	3,41	12,5	6,84
5	St1-t5	2,78	18,5	6,06
6	St1-t6	2,52	NA	3,21
7	St1-t7	3,04	19,4	NA
8	St1-t8	3,14	17,6	5,15
9	St1-t9	2,94	17,8	5,82
10	St1-t10	4,05	10,7	8,02
11	St1-t11	3,61	NA	7,77
12	St1-t12	2,42	17,5	5,24
13	St1-t13	2,71	NA	3,51
14	St1-t14	1,95	NA	4,07
15	St1-t15	2,85	NA	5,86
16	St1-t16	3,32	15,5	NA
17	St1-t17	3,58	11,8	7,83
18	St2-t1	3,61	14,6	6,96
19	St2-t2	3,97	NA	7,69
20	St2-t3	3,75	11,1	8,17
21	St2-t4	3,85	10,7	8,37
22	St2-t5	3,83	10,9	7,34
23	St2-t6	3,68	13,3	5,83
24	St2-t7	3,87	9,9	6,47
25	St2-t8	3,81	NA	9,30
26	St2-t9	4,24	8,6	8,07
27	St2-t10	4,33	8,8	10,03
28	St2-t11	3,76	12,4	4,49
29	St2-t12	4,12	10,4	6,25
30	W1-t1	7,04	2,3	10,25
31	W1-t2	6,88	2,3	9,91
32	W1-t3	6,42	2,1	7,73
33	W1-t4	6,95	2,2	7,82
34	W1-t5	6,74	2,1	6,77
35	W2-t2	7,74	1,1	9,33
36	W2-t3	7,37	0,8	9,35
37	W2-t4	7,37	0,7	7,88
38	W2-t5	7,37	0,6	9,58
39	W2-t6	8,00	0,6	12,30
40	W2-t7	7,08	1,0	10,86

NA: Data not available/Dane niedostępne.

were loaded diametrically and the loads at failure ( $F$ ) were recorded. The tensile strength was determined by:

$$TS = 0.636 \times \frac{F}{Dt} \quad [2]$$

where  $F$  is the load at failure,  $D$  is the diameter and  $t$  is the thickness of the core sample,  $TS$  is in MPa. The results are presented in Table 3. Two tests were cancelled due to early failure of the sample during preloading.

### 3. Regression Analyses and Artificial Neural Networks (ANN)

In this work, the aim of regression analyses and ANN are to estimate the important mechanical properties of limestone using the minimum number of input. In this way, the researchers and field engineers can estimate the mechanical properties by conducting only one type of experiment rather than conducting several different experiments. For this reason, single variable regression analyses and single input ANN were studied.

Regression analyses was applied to correlate mechanical properties of limestone. While conducting regression analyses, linear, polynomial, logarithmic, power and exponential forms were tested for all of the proposed relations. The form giving the largest coefficient of determination ( $R^2$ ) was selected as the regression relation defining the correlation between the mechanical properties.

ANN can be used to model non-linear multivariable problems by performing massively parallel computing unlike classical mathematical models which are based on serial process of mathematical and logical functions (29). ANN have been used in geotechnical and rock engineering as a predictive tool (30-36). The ANN network is composed of input layer, hidden layer(s) and output layer. The input layer has the neurons for input data, hidden layer has the hidden neurons and output layer has the output neurons for the output. The learning of ANN occurs by finding the optimal network connection weights which will create an output vector as close as possible to the target values of the output vector within an accuracy. The error function is minimized to determine the optimal network connection weights. The optimal network connection weights store the relationship between the input and output variables of the system.

ANN was used in predicting the mechanical properties of limestone. A feed forward back-propagation artificial neural network (ANN) was coded using Fortran programming language. The ANN architecture had 1 input, 2 hidden neuron and 1 output. The number of hidden neurons were found by trial – and-error method based on prediction performance. The inputs are normalized to a range of 0.1 and 0.9 using equation [3]:

$$x_i = 0.1 + \frac{0.8(x_i - x_{mini})}{(x_{maxi} - x_{mini})} \quad [3]$$

where  $x_i$  is the input quantity,  $x_{mini}$  and  $x_{maxi}$  are the maximum and

i warstwy wyjściowej. Warstwa wejściowa składa się z neuronów, do których wprowadzane są sygnały wejściowe (dane), warstwy ukrytej składającej się z neuronów ukrytych i warstwy wyjściowej składającej się z neuronów generujących sygnały wyjściowe (wyniki). Uczenie sieci neuronowej polega na doborze optymalnych wag sieci połączeń, które wygenerują wektor wyjściowy bliski jak to tylko możliwe wartościom celowym wektora wyjścia z daną dokładnością. Funkcja błędu jest minimalizowana dla wyznaczenia optymalnych wag połączenia sieciowego. Optymalne wagi połączenia sieciowego pamiętają związek między zmiennymi wejścia i wyjścia układu.

SSN zastosowano do prognozowania mechanicznych właściwości kamienia wapiennego. Algorytm wstecznej propagacji błędu uczenia sztucznej sieci neuronowej zapisano w języku Fortran. SSN zbudowano z jednego wejścia, dwóch ukrytych neuronów i jednego wyjścia. Liczba ukrytych neuronów została określona metodą prób i błędów, w oparciu o prognozowane dopasowanie. Dane wejściowe znormalizowano w zakresie od 0,1 do 0,9 stosując zależność [3]:

$$x_i = 0.1 + \frac{0.8(x_i - x_{mini})}{(x_{maxi} - x_{mini})} \quad [3]$$

gdzie:  $x_i$  jest daną wejściową,  $x_{mini}$  i  $x_{maxi}$  są wartościami minimum i maksimum  $i$  – tego neuronu w warstwie wejściowej odpowiednio dla wszystkich wektorów danych wejściowych. Dana wejściowa jest mnożona przez wagi połączeń  $v_{ij}$ :

$$net_j = \sum x_i v_{ij} - b_j \quad [4]$$

Neurony warstwy ukrytej dodają ważony sygnał wejściowy otrzymany od każdego neuronu wejściowego ( $x_i v_{ij}$ ), łącząc go ze składnikiem stałym ( $b_j$ ), jeśli istnieje. Dalej przekształcają wynik ( $net_j$ ) na sygnał wyjściowy stosując w tym celu powszechnie używaną sigmoidalną funkcję aktywacji (równanie [5]).

$$f(net_j) = \frac{1}{1 + e^{-net_j}} \quad [5]$$

SSN uczy się poprzez powszechnie stosowany algorytm wstecznej propagacji błędu. Zadaniem tego algorytmu jest określenie optymalnych wag do generowania wektora wyjściowego  $\mathbf{Y} = (y_1, y_2, \dots, y_p)$  o składowych wektora wyjściowego najbliższym składowym wektora wyjściowego  $\mathbf{T} = (t_1, t_2, \dots, t_p)$  z zadaną dokładnością. Zadana funkcja błędu ( $E$ ) jest minimalizowana w celu uzyskania optymalnych wag (37):

$$E = \sum_p \sum_p (y_i - t_i)^2 \quad [6]$$

gdzie:  $y_i$  jest składową wektora wyjścia  $\mathbf{Y}$  sieci neuronowej,  $t_i$  jest składową wektora wymaganych sygnałów wyjściowych  $\mathbf{T}$ ,  $p$  jest liczbą neuronów warstwy wyjściowej,  $P$  liczbą wzorców. W algorytmie wstecznej propagacji błędu sygnały wejściowe przechodzą przez sieć do warstwy wyjściowej. Wyliczany jest błąd i wagi są modyfikowane używając metody największego spadku gradientu z zastosowaniem pochodnej funkcji złożonej (37) jak w równaniu [7]:

minimum values of the  $i$  th neuron in the input layer for all the feed data vectors, respectively. The data is multiplied by connection weights  $v_{ij}$ .

$$net_j = \sum x_i v_{ij} - b_j \quad [4]$$

Hidden layer neurons add up the weighted input received from each input neuron ( $x_i v_{ij}$ ), associates it with a bias ( $b_j$ ), if any, and then passes the result ( $net_j$ ) on through a generally employed non-linear sigmoid transfer function (equation [5]).

$$f(net_j) = \frac{1}{1 + e^{-net_j}} \quad [5]$$

The ANN learns by the most commonly used back-propagation algorithm. The task of the back-propagation algorithm is to determine the optimal weights that will generate an output vector  $\mathbf{Y} = (y_1, y_2, \dots, y_p)$  as close to the target values of the output vector  $\mathbf{T} = (t_1, t_2, \dots, t_p)$  as possible with the selected accuracy. A predetermined error function ( $E$ ) is minimized to obtain the optimal weights (37):

$$E = \sum_p \sum_p (y_i - t_i)^2 \quad [6]$$

where  $y_i$  is the component of an ANN output vector  $\mathbf{Y}$ ,  $t_i$  is the component of a target output vector  $\mathbf{T}$ ,  $p$  is the number of output neurons,  $P$ : number of training patterns.

In back-propagation algorithm, the input is passed through the network to the output layer. The error is calculated and the weights are modified using gradient descent method with chain rule of differentiation (37) as in equation [7]:

$$\Delta v_{ij}(n) = -\delta \frac{\partial E}{\partial v_{ij}} + \alpha_m \Delta v_{ij}(n-1) \quad [7]$$

where  $\Delta v_{ij}(n)$  and  $\Delta v_{ij}(n-1)$  are weight increments between node  $i$  and  $j$  during the  $n$  th and  $(n-1)$  th pass or epoch;  $\delta$  is the learning rate and  $\alpha_m$  is the momentum factor.

The bias values was also corrected using an equation similar to equation [7]. The learning rate was used to avoid the training process to be trapped in a local minimum instead of a global minimum. Although a learning rate is used, the solution can still be trapped in a local minimum. An oscillatory path is followed by the solution which slows down the training process. The momentum factor speeds up the training in very flat regions of the error surface and prevent oscillations in the weights (38). The learning rate and momentum factor are important parameters of ANN model. The selection of learning rate and momentum factor have been studied by other researchers (34,39, 40). In this study a trial –and-error method was conducted to select the learning rate and momentum factor. The learning rate and momentum factor were both selected as 0.1.

At the beginning of training, the weights and biases of the network should be set to small random values. Also, the sigmoid function used extends asymptotically to minus and plus infinity and never reaches zero or one. If the input data is fed as is, the large values of input data will require very small weighting factors which will cause



$$\Delta v_{ij}(n) = -\delta \frac{\partial E}{\partial v_{ij}} + \alpha_m \Delta v_j(n-1) \quad [7]$$

gdzie:  $\Delta v_{ij}(n)$  i  $\Delta v_{ij}(n-1)$  są modyfikacją wagi między węzłem  $i$ -tym oraz  $j$ -tym podczas  $n$ -tego i  $n-1$  przejścia wektora wejściowego lub epoki;  $\delta$  szybkością uczenia się,  $\alpha_m$ , współczynnikiem momentum (parametrem bezwładności).

Wartości stałe są również zmieniane stosując równanie podobne do równania [7]. Zastosowano współczynnik szybkości uczenia, aby uniknąć zatrzymania uczenia się sieci w lokalnym minimum, w odróżnieniu od minimum globalnego. Pomimo zastosowania współczynnika szybkości uczenia się uczenie może utknąć w lokalnym minimum. Następuje wówczas oscylacja wokół optymalnego rozwiązania co spowalnia uczenie się. Czynnikiem momentum przyspiesza uczenie się w bardzo płaskich obszarach powierzchni błędu i zapobiega oscylacji wag (38). Szybkość uczenia i współczynnik momentum są ważnymi parametrami modelu SSN. Wybór szybkości uczenia i czynnika momentum był przedmiotem badań prowadzonych przez różnych badaczy (34,39, 40). W niniejszej pracy zastosowano metodę prób i błędów do doboru szybkości uczenia i czynnika momentum. W obu przypadkach przyjęto wartość 0,1.

Na początku procesu uczenia sieci powinny zostać wybrane małe i losowe wartości wag i wartości stałych. Także zastosowana sigmoidalna funkcja aktywacji zmierza asymptotycznie do wartości zero lub jeden od minus do plus nieskończoności. Jeśli dana wejściowa jest wprowadzona w stanie w jakim jest, to duża wartość danej wejściowej wymagać będzie bardzo małych czynników ważących, które wywołają problemy uczenia się sieci (41). Dlatego dana wejściowa jest normalizowana między 0,1 a 0,9 stosując równanie [3]. Szczegóły działania SSN są dostępne w literaturze (42, 43).

Dane zawarte w tabelicy 2 i tabelicy 3 zostały rozdzielone na ciągi uczące i ciągi weryfikujące. Ciągi uczące były zastosowane do wyskalowania modeli regresji i do uczenia SSN. Ciągi weryfikujące zastosowano do zbadania dopasowania modelu regresji, SSN i modeli znanych z literatury. Liczba składowych w ciągach danych, wartość minimalna, średnia, maksymalna i odchylenie standardowe każdego ciągu uczącego i każdego ciągu weryfikującego są zestawione w tabelicy 4. Jak to widać w tabelicy 4 statystyki ciągów uczących i weryfikujących są porównywalne i nie ma błędu w wyborze ciągów uczących i weryfikujących.

Średni błąd absolutny (MAE) i średni względny błąd absolutny (MARE) zastosowano do porównania dopasowania proponowanych modeli regresji, SSN i modeli dostępnych w literaturze. Definicje MAE i MARE są dane równaniami (8, 9):

$$MAE = \frac{\sum |C_{meas} - C_{model}|}{N} \quad [8]$$

$$MARE = \frac{1}{N} \sum \frac{|C_{meas} - C_{model}|}{C_{meas}} \times 100 \quad [9]$$

Table 4 / Table 4

STATYSTYKI CIAGÓW UCZACYCH I WERYFIKUJĄCYCH

TRAINING AND TEST SETS STATISTICS

	Training set Ciąg uczący		Test set Ciąg weryfikacyjny	
	UCS, MPa	H	UCS, MPa	H
Number of data	23	23	14	14
Minimum	48	29	62	28
Mean	85	33	89	33
Maximum	165	40	153	40
St. Dev.	33	4	32	4
	E, GPa	H	E, GPa	H
Number of data	19	19	14	14
Minimum	8	29	8	28
Mean	13	33	14	33
Maximum	32	40	31	40
St. Dev.	8	3	9	4
	E, GPa	V, km/s	E, GPa	V, km/s
Number of data	19	19	14	14
Minimum	8	3,15	8	3,15
Mean	13	3,66	14	3,74
Maximum	32	5,67	31	5,58
St. Dev.	8	0,76	9	0,87
	E, GPa	UCS, MPa	E, GPa	UCS, MPa
Number of data	19	19	14	14
Minimum	8	48	8	52
Mean	13	77	14	83
Maximum	32	153	31	157
St. Dev.	8	24	9	29
	TS, MPa	V, km/s	TS, MPa	V, km/s
Number of data	24	24	14	14
Minimum	3	1,95	5	2,42
Mean	7	4,38	8	4,66
Maximum	12	8,00	11	7,74
St. Dev.	2	1,79	2	1,96
	TS, MPa	p, %	TS, MPa	p, %
Number of data	19	19	10	10
Minimum	4	0,6	5	0,6
Mean	8	8,3	8	9,1
Maximum	12	18,5	11	17,8
St. Dev.	2	5,9	2	7,1
	V, km/s	p, %	V, km/s	p, %
Number of data	20	20	11	11
Minimum	2,78	0,6	2,42	0,6
Mean	4,93	8,9	4,65	9,7
Maximum	8,00	19,4	7,37	17,8
St. Dev.	1,85	6,3	1,89	7,0

gdzie: dla każdej wartości,  $C_{meas}$  jest wartością zmierzoną i  $C_{model}$  jest wartością obliczoną przy użyciu modelu;  $N$  jest liczbą wyrazów w ciągu.

#### 4. Wyniki i dyskusja

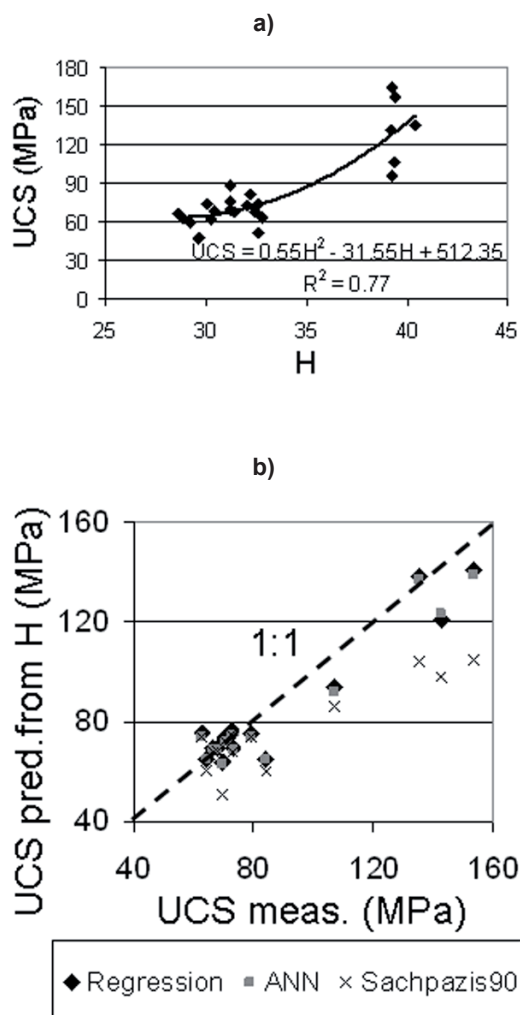
Poniżej przedstawione są wyniki analizy regresji oraz SSN. Dopasowanie modeli regresji i SSN zawartych w niniejszym artykule jest porównane z dopasowaniem modeli znanych z literatury. Jeśli tylko było możliwe, to dla każdej zależności wybrano jeden model ze znanych z literatury. Przede wszystkim wybierano model konstruowany na wynikach doświadczeń wykonanych na kamieniu wapiennym. Następnie wybrane modele były sprawdzane przy użyciu weryfikujących zbiorów danych. Modele wykazujące najmniejsze wartości błędów ( $MAE$ ,  $MARE$ ) wybrano do porównania z równaniami SSN i regresji przedstawionymi w niniejszym artykule. Dlatego model znany z literatury zbudowany na podstawie wyników pochodzących z badań wapienia i do porównania wybrano dający najmniejszy błąd. Wartości  $MAE$  i  $MARE$  modeli regresji, SSN i modeli zaczerpniętych z literatury są zawarte w tablicy

problems (41). Therefore, the input data is normalized between 0.1 and 0.9 using equation [3]. The details of ANN is available at the literature (42, 43).

The data given in table 2 and table 3 were separated to training and test sets. The training sets were used to calibrate regression models and to train ANN. The test sets were used to test the performance of the regression model, ANN and the models available in the literature. The number of elements in data sets, minimum, mean, maximum and standard deviation of each training and test sets are presented in table 4. As seen in table 4, the statistics of the training and test sets are comparable and there is no bias in the selection of the training and test sets.

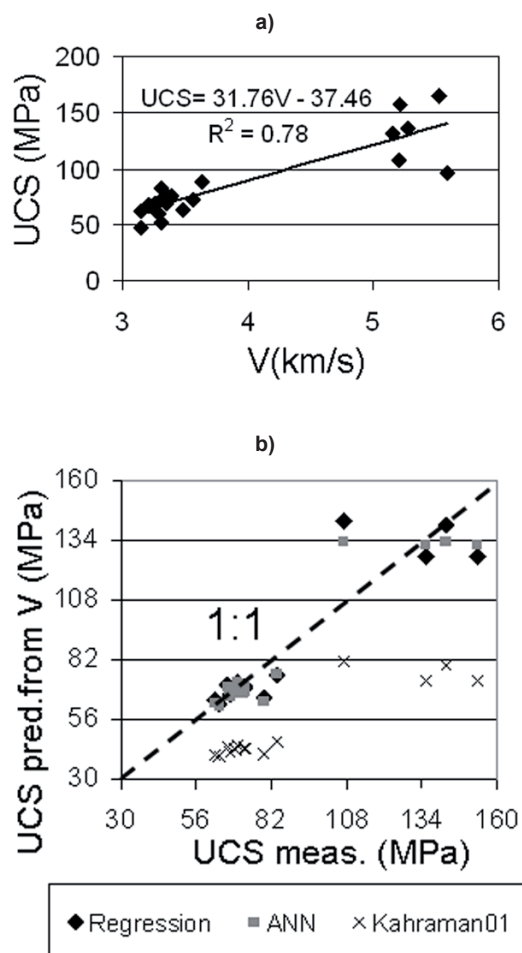
The Mean Absolute Error ( $MAE$ ) and the Mean Absolute Relative Error ( $MARE$ ) were used to compare the performances of the proposed regression models, ANN and the models available in the literature. The formulations of  $MAE$  and  $MARE$  are presented in Eqs.(8-9):

$$MAE = \frac{\sum |C_{meas} - C_{model}|}{N} \quad [8]$$



Rys. 5 (a) Model regresji dla związku UCS-H, (b) UCS prognozowane z zależności H i mierzonej wartości UCS

Fig. 5 (a) Regression model of UCS-H relation (b) UCS predicted from H versus UCS measured



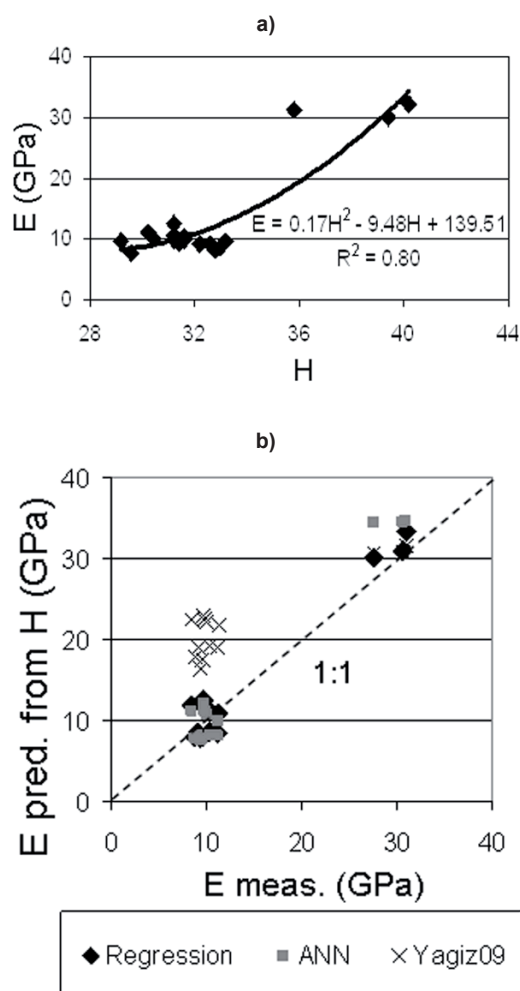
Rys. 6 (a) Model regresji zależności UCS-V, (b) Wartości UCS prognozowane z wartości V w zależności od mierzonego UCS

Fig. 6 (a) Regression model of UCS-V relation (b) UCS predicted from V versus UCS measured

5. Dla każdego związku wykres modelu regresji jest przedstawiony na rysunkach 5 – 12. Także wykres wielkości oczekiwanej w funkcji wielkości mierzonej dla zbioru danych weryfikujących o najlepszym dopasowaniu wykonany przy zastosowaniu linii przerywanej jest przedstawiony na rysunkach 5 – 12 (linia 1:1). Analiza regresji prowadzi do wielomianowego związku między UCS i  $H$  jak to jest przedstawione na rysunku 5(a) i w równaniu [10] z  $R^2=0.77$ :

$$UCS = 0.55H^2 - 31.55H + 512.35 \quad [10]$$

Wyniki istniejących badań zawarte w literaturze dla związku między UCS i  $H$  (Tablica 5) zostały otrzymane przy użyciu młotka Schmidta typu L, tak jak w badaniach przedstawionych w niniejszym artykule. Istniejące modele o najmniejszej wartości MAE i MARE dla związku między UCS- $H$  zostały opracowane przez Sachpazisa (1990) (11) oraz O'Rourke'a (1989) (15) i mają porównywalne wartości MAE i MARE. Sachpazis (1990) (11) zbadał 33 różnych węglanów, w tym 29 z Grecji i 4 z Anglii. O'Rourke (15) zbadał piaskowiec drobnziarnisty, piaskowiec i kamień wapienny pochodzące z Utah, USA. Badania własne autorów artykułu dotyczyły na kamienia wapiennego z zachodniego wybrzeża Turcji, w pobliżu Grecji. Dlatego mając na uwadze rodzaj i pochodzenie kamienia model Sachpazisa (1990) (11) został wybrany do porównań



Rys. 7 (a) Model regresji zależności  $E-H$  (b)  $E$  prognozowane z wartości  $H$  w zależności od mierzonego  $E$


Fig. 7 (a) Regression model of  $E-H$  relation (b)  $E$  predicted from  $H$  versus  $E$  measured

$$MARE = \frac{1}{N} \sum \frac{|C_{meas} - C_{model}|}{C_{meas}} \times 100 \quad [9]$$

where for any quantity,  $C_{meas}$  is measured and  $C_{model}$  is model estimation;  $N$  is the number of elements in the set.

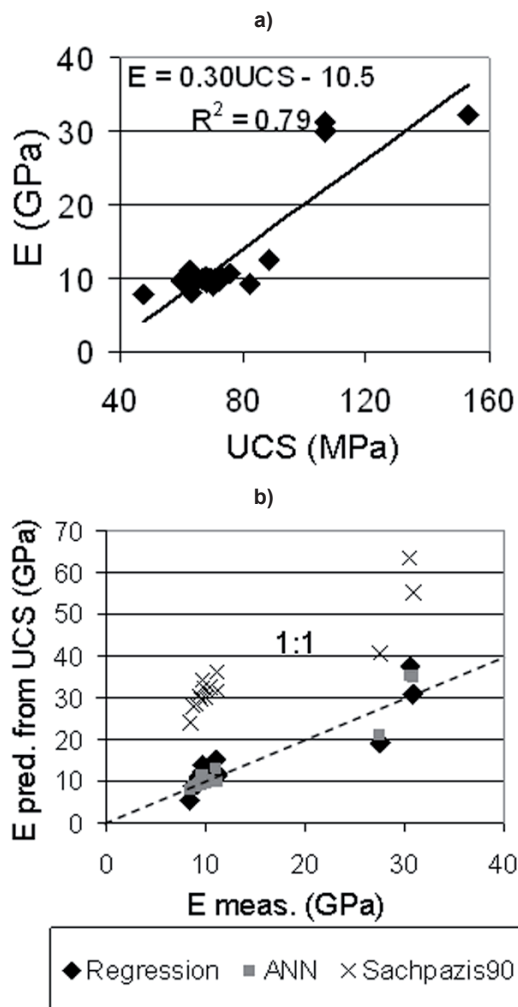
#### 4. Results and discussion

The results of the regression analyses and ANN are presented in this section. Also the performances of the regression models and ANN developed in this study are tested with the existing models in the literature. For each relation, one existing model was selected, if available. The existing model derived from the experiments conducted on limestone was first selected. Then, the selected existing models were applied on testing data sets. The ones produced the minimum errors (MAE, MARE) were selected for comparison with the ANN and the regression equations developed in this study. Thus, the existing literature model, conducted on limestone and giving minimum error was selected for comparison. The MAE and MARE of the regression models, ANN and literature models are presented in Table 5. For each relation, regression model graph having dependent and independent variable as axis is given in Figs. 5-12. Also, a test graph of predicted versus measured quantity, having a dashed line for perfect fit (1:1 line) is presented in Figs. 5-12.



Rys. 8 (a) Model regresji zależności  $E-V$  (b)  $E$  prognozowane z wartości  $V$  w zależności od mierzonego  $E$

Fig. 8 (a) Regression model of  $E-V$  relation (b)  $E$  predicted from  $V$  versus  $E$  measured



Rys. 9 (a) Model regresji zależności  $E$ – $UCS$  (b)  $E$  prognozowane z wartości  $UCS$  w zależności od mierzonego  $E$

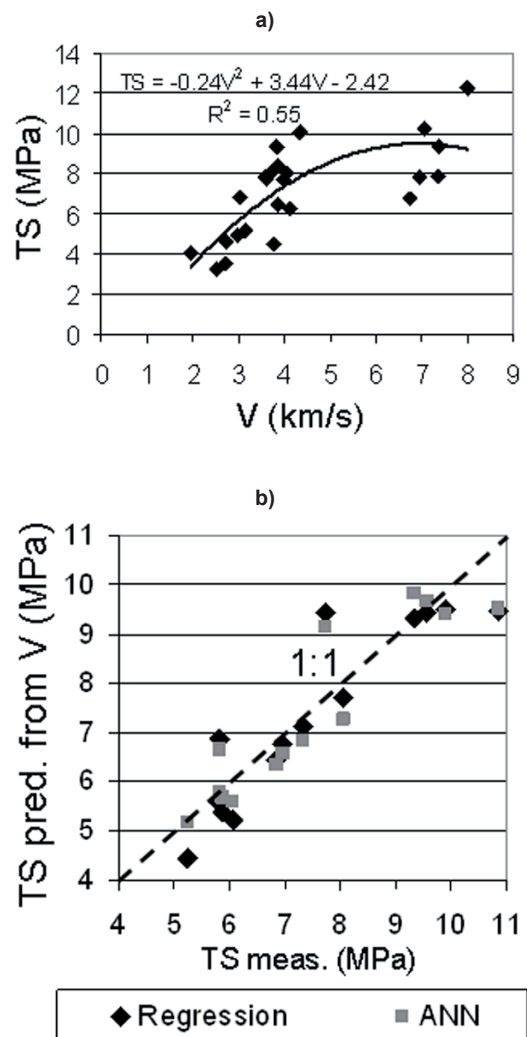
Fig. 9 (a) Regression model of  $E$ – $UCS$  relation (b)  $E$  predicted from  $UCS$  versus  $E$  measured

z modelem regresji i SSN zbudowanych na wynikach własnych. Wartości  $MAE$  i  $MARE$  modelu regresji i SSN są niższe niż wartości  $MAE$  i  $MARE$  wynikające z badań Sachpazisa (1990) (11), co jest widoczne w tabelicy 5. Wyniki modelu regresji i SSN są bliższe linii najlepszego dopasowania na rysunku 5(b). Model Sachpazisa (1990) (11) daje za małe wartości  $UCS$  w funkcji  $H$ , szczególnie w zakresie większych wartości  $H$  jak to widać na rysunku 5(b). Modele regresji i SSN opracowane na podstawie wyników uzyskanych przez autorów są lepsze do estymacji  $UCS$  na podstawie wartości  $H$  w stosunku do modelu Sachpazisa (1990) (11).

Model regresji dla oszacowania  $UCS$ (MPa) z  $V$  (km/s) jest przedstawiony na rysunku 6(a) i za pomocą równania [11] ze współczynnikiem dopasowania  $R^2 = 0.78$ .

$$UCS = 3.76V - 37.46 \quad [11]$$

Jak wynika z tabelicy 5 dla oszacowania  $UCS$  z wartości  $V$  znany w literaturze model o najniższym  $MAE$  i  $MARE$  to model Kahramana (2001) (13). Także modele regresji i SSN są bliższe linii najlepszego dopasowania (linia 1:1) w odniesieniu do modelu Kahramana (2001) (13) co jest widoczne na rysunku 6(b). Model Kahramana (2001) (13) daje za małe wartości  $UCS$  na pod-



Rys. 10 (a) Model regresji zależności  $TS$  –  $V$  (b)  $TS$  prognozowane z wartości  $V$  w zależności od mierzonego  $TS$

Fig. 10 (a) Regression model of  $TS$ – $V$  relation (b)  $TS$  predicted from  $V$  versus  $TS$  measured

The regression analyses yield the polynomial relation between  $UCS$  and  $H$  as presented in Fig. 5(a) and equation [10] with a  $R^2 = 0.77$ .

$$UCS = 0.55H^2 - 31.55H + 512.35 \quad [10]$$

The existing studies selected from the literature for relation between  $UCS$  and  $H$  (Table 5) were conducted with L type Schmidt hammer as in this study. The existing models having the lowest  $MAE$  and  $MARE$  for  $UCS$ – $H$  relation belongs to Sachpazis (1990) (11) and O'Rourke (1989) (15) which have comparable  $MAE$  and  $MARE$ . Sachpazis (1990) (11) worked on 33 different carbonates; 29 of them were from Greece and 4 from England. O'Rourke (15) worked on siltstone, sandstone and limestone obtained from Utah, USA. This study is on limestone obtained from west coast of Turkey, close to Greece. Thus, considering the types and locations of the stones, the model of Sachpazis (1990) (11) was selected for comparison with regression model and ANN of this study. The  $MAE$  and  $MARE$  of the regression model and ANN is lower than the  $MAE$  and  $MARE$  obtained from Sachpazis (1990) (11) as seen in Table 5. The regression model and ANN predictions are closer

Tablica 5 / Table 5

ŚREDNI BŁĄD ABSOLUTNY (MAE), ŚREDNI WZGLĘDNY BŁĄD ABSOLUTNY (MARE) I R<sup>2</sup> DLA KAŻDEGO MODELU

MEAN ABSOLUTE ERROR (MAE), MEAN ABSOLUTE RELATIVE ERROR (MARE) AND R<sup>2</sup> FOR EACH MODEL

	Regression Model	ANN	Yasar & Erdogan (2004)	Kahraman (2001)	Sachpazis (1990)	O'Rourke (1989)	Cobanoglu & Celik (2008)	Yagiz (2009)
<b>UCS-H</b>								
MAE (MPa)	<b>7,62</b>	<b>7,52</b>	74	NA	<b>15,6</b>	14,2	81	64
MARE (%)	<b>8,23</b>	<b>8,07</b>	84	NA	<b>14,8</b>	15,5	97	71
R <sup>2</sup>	<b>0,91</b>	<b>0,92</b>	0,88	NA	<b>0,8</b>	0,8	0,8	0,85
<b>UCS-V</b>								
MAE (MPa)	<b>7,9</b>	<b>7,3</b>	NA	<b>37</b>	NA	NA	62	NA
MARE (%)	<b>7,8</b>	<b>7,4</b>	NA	<b>40</b>	NA	NA	82	NA
R <sup>2</sup>	<b>0,82</b>	<b>0,89</b>	NA	<b>0,82</b>	NA	NA	0,82	NA
<b>E-H</b>								
MAE (GPa)	<b>1,7</b>	<b>2,4</b>	NA	NA	15	NA	NA	<b>8</b>
MARE (%)	<b>15</b>	<b>17,4</b>	NA	NA	138	NA	NA	<b>84</b>
R <sup>2</sup>	<b>0,96</b>	<b>0,96</b>	NA	NA	0,83	NA	NA	<b>0,83</b>
<b>E-V</b>								
MAE (GPa)	<b>1,4</b>	<b>1,2</b>	NA	NA	NA	NA	NA	NA
MARE (%)	<b>10</b>	<b>8</b>	NA	NA	NA	NA	NA	NA
R <sup>2</sup>	<b>0,96</b>	<b>0,98</b>	NA	NA	NA	NA	NA	NA
<b>E-UCS</b>								
MAE (GPa)	<b>2,4</b>	<b>1,7</b>	NA	NA	<b>22</b>	NA	NA	NA
MARE (%)	<b>17</b>	<b>9,5</b>	NA	NA	<b>185</b>	NA	NA	NA
R <sup>2</sup>	<b>0,84</b>	<b>0,92</b>	NA	NA	<b>0,84</b>	NA	NA	NA
<b>TS-V</b>								
MAE (MPa)	<b>0,6</b>	<b>0,6</b>	NA	NA	NA	NA	NA	NA
MARE (%)	<b>8</b>	<b>7</b>	NA	NA	NA	NA	NA	NA
R <sup>2</sup>	<b>0,83</b>	<b>0,85</b>	NA	NA	NA	NA	NA	NA
<b>TS-p</b>								
MAE (MPa)	0,6	0,6	NA	NA	NA	NA	NA	NA
MARE (%)	7,7	8	NA	NA	NA	NA	NA	NA
R <sup>2</sup>	0,82	0,81	NA	NA	NA	NA	NA	NA
<b>V-p</b>								
MAE (MPa)	0,27	0,28	NA	NA	NA	NA	NA	NA
MARE (%)	6,21	7,1	NA	NA	NA	NA	NA	NA
R <sup>2</sup>	0,98	0,98	NA	NA	NA	NA	NA	NA

**Bold** values are used for comparison of performance in the measured versus predicted test graphs / Wartości zaznaczone **łustym drukiem** stosuje się do porównania efektywności modeli otrzymanych z wartości zmierzonych i modeli znanych z literatury.

NA: No relation exist for lime stone in the given reference / Nie ma żadnego związku dla kamienia wapiennego w danej pozycji literaturowej.

stawie wartości *V*. Dopasowania modeli regresji i SSN opracowanych przez autorów są lepsze niż dopasowanie modelu Kahramana (2001) (13).

Równanie [12] otrzymano z modelu regresji dla estymacji *E* (GPa) z wartości *H* ze współczynnikiem dopasowania  $R^2 = 0.8$ , co jest widoczne na rysunku 7(a).

$$E = 0.17H^2 - 9.48H + 139.51 \quad [12]$$

to perfect fit line (1:1 line) in Fig. 5(b). The model of Sachpazis (1990) (11) under-estimates the *UCS* from *H*, especially at the higher *H* values, as seen in Fig. 5(b). The regression model and ANN performed in this study have higher performance for predicting *UCS* from *H* with respect to model of Sachpazis (1990) (11).

The regression model for estimation of *UCS* (MPa) from *V* (km/s) is in Fig. 6(a) and in equation [11], with a  $R^2 = 0.78$ .

Jak wynika z tablicy 5 model Yagiza (2009) (17) daje najniższe *MAE* i *MARE* w porównaniu z innym modelem znanym z literatury. Wartości *MAE* i *MARE* modelu regresji i modelu SSN są niższe niż wartości *MAE* i *MARE* modelu Yagiza (2009) (17). Modele regresji i SSN są bliższe linii najlepszego dopasowania (linia 1:1), podczas gdy model Yagiza (2009) (17) daje za duże wartości *E* w zależności od *H* jak to widać na rysunku 7(b). Dopasowania modelu regresji i SSN są lepsze niż dopasowanie modelu Yagiza (2009) (17).

Model regresji pokazany na rysunku 8(a) pokazuje związek między *E*(GPa) i *V* (km/s) wyrażony za pomocą równania [13] z  $R^2 = 0.97$ .

$$E = 10.46V - 25.25 \quad [13]$$

Wartości *MAE* i *MARE* modelu regresji i SSN są niewielkie jak to widać w tablicy 5. Model regresji i SSN są bardzo bliskie linii najlepszego dopasowania (linia 1:1) pokazanej na rysunku 8(b).

Równanie [14] jest równaniem modelu regresji dla estymacji wartości *E*(GPa) w zależności od wartości zmiennej *UCS*(MPa) jak to jest pokazane na rysunku 9(a) z  $R^2 = 0.79$ .

$$E = 0.3UCS - 10.5 \quad [14]$$

Wartości *MAE* i *MARE* modelu regresji i SSN są znacznie niższe w porównaniu z wartościami *MAE* i *MARE* modelu proponowanego przez Sachpazisa (1990) (14). Modele regresji i SSN są bliskie linii najlepszego dopasowania (linia 1:1) podczas gdy model Sachpazisa (1990) (14) daje za duże *E* z wartości *UCS* jak to widać na rysunku 9(b).

Równanie [15] otrzymano z regresji *TS*(MPa) względem *V* (km/s) z  $R^2 = 0.55$  jak to widać na rysunku 10(a).

$$TS = -0.24V^2 + 3.44V - 2.42 \quad [15]$$

Wartości *MAE* i *MARE* modelu regresji i SSN dla prognozowania zależności *TS* – *V* są małe jak to wynika z tablicy 5. Modele regresji i SSN są bardzo bliskie linii najlepszego dopasowania (linia 1:1) na rysunku 10(b).

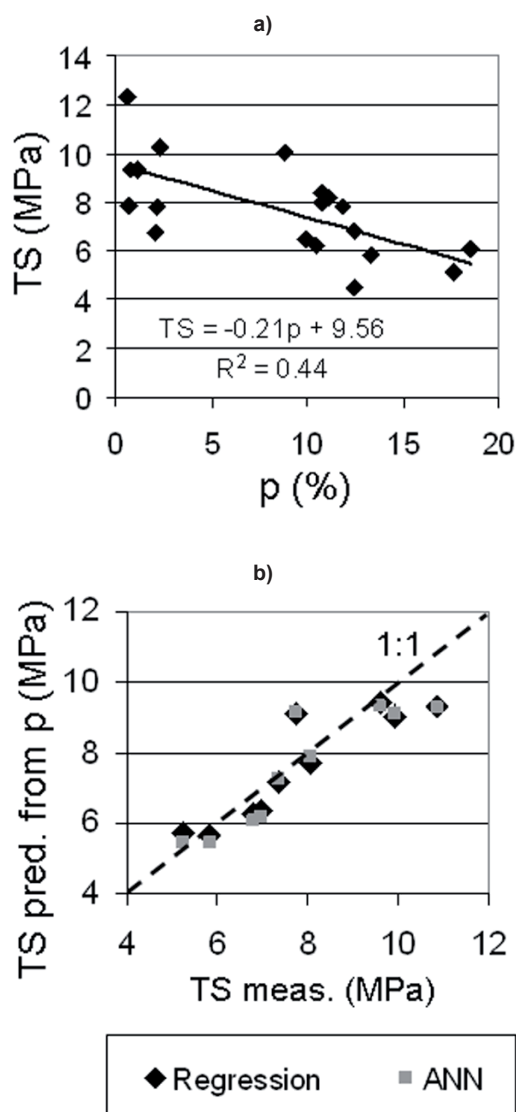
Równanie [16] jest równaniem modelu regresji *TS* (MPa) względem *p* (%) ze współczynnikiem dopasowania  $R^2 = 0.44$  co pokazano na rysunku 11(a). Wartości *MAE* i *MARE* modelu regresji i SSN są małe dla zależności *TS* - *p*. Modele regresji i SSN są bliskie linii najlepszego dopasowania (linia 1:1) na rysunku 11(b).

$$TS = -0.21p + 9.56 \quad [16]$$

Równanie [17] wynika z modelu regresji pokazanego na rysunku 12(a) dla oszacowania *V* (km/s) w zależności od *p*(%) z  $R^2 = 0.98$ . Wartości *MAE* i *MARE* są za małe dla zależności *V* - *p* w tablicy 5 podczas gdy zarówno modele regresji jak i SSN są bardzo bliskie linii najlepszego dopasowania (linia 1:1) na rysunku 12(b).

$$V = 0.014p^2 - 0.53p + 8.01 \quad [17]$$

Wyniki przedstawione w niniejszej części artykułu wskazują na dobre dopasowanie modeli regresji i SSN w prognozowaniu właściwości mechanicznych kamienia wapiennego. Modele mogą być sto-



Rys. 11 (a) Model regresji zależności *TS*–*p* (b) *TS* prognozowane z wartości *p* w zależności od mierzonego *TS*

Fig. 11 (a) Regression model of *TS*–*p* relation (b) *TS* predicted from *p* versus *TS* measured

$$UCS = 3.76V - 37.46 \quad [11]$$

For estimation of *UCS* from *V*, the existing model having the lowest *MAE* and *MARE* is the model of Kahraman (2001) (13) as seen in Table 5. The *MAE* and *MARE* of regression model and ANN are much lower than the *MAE* and *MARE* of Kahraman (2001) (13). Also, the regression model and ANN is more closer to perfect fit line (1:1) than model of Kahraman (2001) (13) as in Fig. 6(b). The model of Kahraman (2001) (13) under-estimates *UCS* from *V*. The performances of regression model and ANN performed in this study are better than performance of the model of Kahraman (2001) (13).

Equation [12] is obtained from regression model for estimation of *E*(GPa) from *H* with a  $R^2 = 0.8$  as seen in Fig. 7(a).

$$E = 0.17H^2 - 9.48H + 139.51 \quad [12]$$

The model of Yagiz (2009) (17) gives the minimum *MAE* and *MARE* in the literature as seen in Table 5. The *MAE* and *MARE* of regression model and ANN are lower than the *MAE* and *MARE*

sowane przez naukowców do badań i renowacji historycznych murów, a także do nowych budowli wykonanych z użyciem wapienia.


## 5. Wnioski

W przemyśle cementowym i betonowym wapień jest podstawowym surowcem. Oszacowanie mechanicznych właściwości wapienia jest ważne dla jego zastosowań. Twardość Schmidta, szybkość fali ultradźwiękowej, porowatość, wytrzymałość na jednoosiowe ściskanie i pośrednia próba rozciągania zbadano na próbkach wapienia otrzymanym z murowanej, historycznej budowli. Modele regresji i SSN zostały opracowane dla estymowania mechanicznych właściwości wapienia w próbach nieniszczących, a także prostych do wykonania badań niszczących. Opracowane modele zostały porównane z modelami znanymi z literatury, a skonstruowanymi na podstawie badań właściwości mechanicznych wapieni. Modele zwarte w niniejszej pracy mają wysoki współczynnik determinacji prognozowania mechanicznych właściwości wapienia.

Po raz pierwszy w literaturze zastosowano sztuczną sieć neuronową do estymowania mechanicznych właściwości wapienia. Użycie osobnych ciągów uczących i weryfikujących w analizie regresji jest po raz pierwszy przeprowadzone do estymowania mechanicznych właściwości wapienia. Modele regresji i SSN są po raz pierwszy zastosowane do prognozowania mechanicznych właściwości wapienia pozyskanego z historycznej budowli. Niektóre modele regresji przedstawione w niniejszym artykule są po raz pierwszy publikowane (związek między wytrzymałością na rozciąganie i szybkością fali, wytrzymałością na rozciąganie i porowatością, szybkością fali i porowatością).

Klazomenai, jedno ze starożytnych miast okręgu Ioni, ma budowle bardzo bliskie tym, z których pozyskano wapień do wykonania badań przedstawionych w artykule. Klazomenai, jest wspomniane przez sławnego historyka Herodotusa Halikarnasusa (484-425 p.n.e.). W Klazomenai znajduje się druga z najstarszych fabryk oliwy w świecie. Wapień podobny do jednego z badanych w niniejszym artykule został użyty w budynku starożytnego miasta Klazomenai i w starożytnej fabryce oliwy. Ze względu na ochronę zabytków nie jest możliwe pobieranie próbek w starożytnym mieście lub starożytnej fabryce. Naukowcy mogą stosować modele przedstawione w niniejszym artykule do właściwości wapieni starożytnego miasta Klazomenai i starożytnej fabryki oliwy.

Wapień jest powszechnie stosowanym materiałem budowlanym w wielu murowanych obiektach historycznych. Ponadto był stosowany w budowie murów oporowych, ziemnych budowlach nośnych, podbudowach autostrad i murowanych budynkach na całym świecie. Modele opracowane w niniejszych badaniach mogą być stosowane przez naukowców i inżynierów do estymacji mechanicznych właściwości wapienia.



Rys. 12 (a) Model regresji zależności  $V$ - $p$  (b)  $V$  estymowane z wartości  $p$  w zależności od mierzonego  $V$

Fig. 12 (a) Regression model of  $V$ - $p$  relation (b)  $V$  predicted from  $p$  versus  $V$  measured

for the model of Yagiz (2009) (17). The regression model and ANN is close to perfect fit line (1:1) while Yagiz (2009) (17) overestimates the  $E$  from  $H$  as seen in Fig. 7(b). The performance of the regression model and ANN are better than the performance of the model of Yagiz (2009) (17).

The regression model obtained at Fig. 8(a) gives the relation between  $E$ (GPa) and  $V$  (km/s) as in equation [13] with  $R^2=0.97$ .

$$E = 10.46V - 25.25 \quad [13]$$

The  $MAE$  and  $MARE$  of the regression model and ANN are low as seen in Table 5. The regression model and ANN is very close to perfect fit line (1:1) in Fig. 8(b).

The regression model yields equation [14] for estimation of  $E$ (GPa) from  $UCS$ (MPa) as seen in Fig. 9(a), with  $R^2 = 0.79$ .

$$E = 0.3UCS - 10.5 \quad [14]$$

The  $MAE$  and  $MARE$  of the regression model and ANN are much lower than the  $MAE$  and  $MARE$  of the model proposed by Sachpazis (1990) (14). The regression model and ANN is close

## Podziękowanie

Dziękujemy Tureckiej Radzie Badań Naukowych i Technicznych (TUBITAK) za sfinansowanie projektu ICTAG I-591.

## Literatura / References

1. G. Croci, The Conservation and Structural Restoration of Architectural Heritage. Computational Mechanics Publications, Boston, USA, (1998).
2. Ö. Eren, M. Bahali, Some engineering properties of natural building cut stones of Cyprus. *Constr. Build. Mater.*, Vol.19, 213-222 (2005).
3. R. Ulusay, K. Tureli, M.H. Ider, Prediction of engineering properties of a selected litharenite sandstone from its petrographic characteristics using correlation and multivariate statistical techniques. *Engineering Geology*, Vol.37, 135-157 (1994).
4. H. Sonmez, C. Gokceoglu, R. Ulusay, An application of fuzzy sets to the Geological Strength Index (GSI) System used in rock engineering. *Engineering Applications of Artificial Intelligence*, Vol. 16, No. 3, 251-269 (2003).
5. F. Pohle, W. Jager, Material properties of historical masonry of the Frauenkirche and the masonry guideline for reconstruction. *Constr. Build. Mater.* Vol.17, 651-667 (2003).
6. B. Tutmez, S. Kahraman, O. Gunaydin, Multifactorial fuzzy approach to the sawability classification of building stones. *Constr. Build. Mater.* Vol.21, 1672-1679 (2007).
7. N. Yilmaz, Z. Karaca, R. Goktan, C. Akal, C. , Relative brittleness characterization of some selected granitic building stones: Influence of mineral grain size. *Constr. Build. Mater.* Vol.23, 370-375 (2009).
8. L. Binda, A. Saisi, C. Tiraboschi, Investigation procedures for the diagnosis of historic masonries. *Constr. Build. Mater.* Vol.14, No. 4, 199-233 (2000).
9. L. Schueremans, K.V. Balen, K. Brosens, D.V. Gemert, P. Smars, The Church of Saint James at Leuven: Structural assessment and consolidation measures. *Int. J. Archit. Herit.* Vol.1, 82-107, (2007).
10. European Committee for Standardization, Eurocode 6: Design of Masonry Structures, Brussels (1996).
11. C.I. Sachpazis, Correlating Schmidt Hardness with Compressive Strength and Young's Modulus of Carbonate Rocks. *Bull. Int. Assoc. Eng. Geol.*, Vol.42, 75-83 (1990).
12. E. Yasar, Y. Erdogan, Estimation of rock physicomaterial properties using hardness methods. *Eng. Geol.* Vol.71, 281-288 (2004).
13. S. Kahraman, Evaluation of simple methods for assessing the uniaxial compressive strength of rock. *Int. J. of Rock Mech. & Min. Sci.*, Vol. 38, 981-994 (2001).
14. C.I. Sachpazis, Correlating Schmidt Hardness with Compressive Strength and Young's Modulus of Carbonate Rocks. *Bull. Int. Assoc. Eng. Geol.*, Vol.42, 75-83 (1990).
15. J.E. O'Rourke, Rock index properties for geoenvironmental engineering in underground development. *Min. Eng.* 106-110 (1989).
16. I. Cobanoglu, S.B. Celik Estimation of uniaxial compressive strength from point load strength, Schmidt hardness and P-wave velocity. *Bull. Eng. Geol. Environ.* Vol.67, 491-498 (2008).
17. S. Yagiz, Predicting uniaxial compressive strength, modulus of elasticity and index properties of rocks using the Schmidt hammer. *Bull. Eng. Geol. Environ.* Vol. 68, 55-63, (2009).
18. A. Aydin, A. Basu, The Schmidt hammer in rock material characterization. *Eng. Geol.*, Vol.81, 1-14 (2005).
19. I. Yilmaz, H. Sendir, Correlation of Schmidt hardness with unconfined compressive strength and Young's modulus in gypsum from Sivas (Turkey). *Eng. Geol.* Vol.66, 211-219 (2002).
20. A. Tugrul, I.H. Zarif, Correlation of mineralogical and textural charac-

to perfect fit line (1:1) while the model of Sachpazis (1990) (14) over-estimates  $E$  from  $UCS$  as seen in Fig. 9(b).

Equation [15] is obtained from regression model for estimation of  $TS$ (MPa) from  $V$ (km/s) with a  $R^2 = 0.55$  as seen in Fig. 10(a).

$$TS = -0.24V^2 + 3.44V - 2.42 \quad [15]$$

The  $MAE$  and  $MARE$  of the regression model and ANN for  $TS$ - $V$  prediction are low as seen in Table 5. The regression model and ANN is very close to perfect fit line (1:1) in Fig. 10(b).

The regression model gives equation [16] for relation between  $TS$  (MPa) and  $p$  (%) with a  $R^2=0.44$  as seen in Fig. 11(a). The  $MAE$  and  $MARE$  of the regression model and ANN are low in Table 5 for  $TS$ - $p$  relation. The regression model and ANN are close to perfect fit line (1:1) in Fig. 11(b).

$$TS = -0.21p + 9.56 \quad [16]$$

Equation [17] is obtained from regression model in Fig. 12(a) for estimating  $V$  (km/s) from  $p$ (%) with a  $R^2 = 0.98$ . The  $MAE$  and  $MARE$  are low for  $V$ - $p$  relation in Table 5 while both regression and ANN are very close to perfect fit line (1:1 line) in Fig. 12(b).

$$V = 0.014p^2 - 0.53p + 8.01 \quad [17]$$

The results presented in this section showed that the regression models and ANN developed in this study have high performance in estimating the mechanical properties of limestone. The models can be used by researchers for analyses and rehabilitation of historical masonry as well as for new constructions having limestone.

## 5. Conclusions

In cement and concrete industry, limestone is an important raw material. The estimation of mechanical properties of limestone is important for cement and concrete industry. Schmidt hardness, ultrasonic wave velocity, porosity, uniaxial compression and indirect tension tests were applied on limestone obtained from a historical masonry structure. Regression models and ANN were developed to estimate the mechanical properties of limestone from non-destructive tests as well as from easy-to-do destructive tests. The developed models were compared with the available models in the literature conducted on limestone. The models presented in this work have a high performance in estimation of mechanical properties of the limestone.

For the first time in the literature, ANN is used to estimate the mechanical properties of limestone. The use of separate training and testing sets for regression analyses is conducted for the first time in the literature for estimation of mechanical properties of limestone. Regression and ANN models are used for the first time to predict the mechanical properties of limestone obtained from a historical structure. Several regression models developed in this work have been published for the first time in the literature for limestone (relations between tensile strength and wave velocity, tensile strength and porosity, wave velocity and porosity).



teristics with engineering properties of selected granitic rocks from Turkey. *Eng. Geol.* Vol. 51, 303–317 (1999).

21. O. Katz, Z. Reches, J.C. Roegiers, Evaluation of mechanical rock properties using a Schmidt Hammer. *Int. J. Rock Mech. Min. Sci.*, Vol. 37, 723–728 (2000).
22. E. Teomete, E. Aktaş, Structural Analyses and Assessment of Historical Kamanlı Mosque in Izmir, Turkey. *J. Performance of Constructed Facilities*, ASCE, Vol. 24, No.4, 353–364 (2010).
23. [http://www.klazomenai.com/index1\\_eng.htm](http://www.klazomenai.com/index1_eng.htm), Accessed: 17/08/2010.
24. <http://en.wikipedia.org/wiki/Klazomenai>, Accessed: 17/08/2010.
25. H. Halikarnasus, *The Histories*, Trans. Aubrey de Selincourt, Baltimore, Penguin Books, ISBN: 0140440348, 1973.
26. F. Erim, *Turkish Era Structures in Urla -1*. Ege University Graduation Thesis, Izmir, Turkey (1995).
27. ISRM (International Society for Rock Mechanics). *Rock Characterization, Testing and Monitoring: ISRM Suggested Methods*. ed. E.T. Brown, Pergamon Press, Oxford (1981).
28. RILEM Commission 25 PEM, Tests defining the structure. *Mater. Constr.* Vol. 13, No.75, 177–181 (1980).
29. L. Fausett, *Fundamental of Neural Networks; Architectures, Algorithm and Application*, Prentice Hall International Editions, New York (1994).
30. C. Gokceoglu, E. Yesilnacar, H. Sonmez, A. Kayabasi, A neuro-fuzzy model for modulus of deformation of jointed rock masses. *Computers and Geotechnics*, Vol. 31, 375–383 (2004).
31. F. Meulenkamp, G.M. Alvarez, Application of neural networks for the prediction of the unconfined compressive strength (UCS) from Equotip hardness. *International Journal of Rock Mechanics and Mining Sciences*, Vol.36, No.1, 29–39 (1999).
32. V.K. Singh, D. Singh, T.N. Singh, Prediction of strength properties of some schistose rocks from petrographic properties using artificial neural Networks. *International Journal of Rock Mechanics and Mining Sciences*, Vol. 38, No.2, 269–284 (2001).
33. T.N. Singh, S. Sinha, V.K. Singh, Prediction of thermal conductivity of rock through physico-mechanical properties. *Building and Environment*, Vol.42, No.1, 146–155 (2007).
34. H. Sonmez, C. Gokceoglu, H.A. Nefeslioglu, A., Kayabasi, Estimation of rock modulus: For intact rock with an artificial neural network and for rock masses with a new empirical equation. *International Journal of Rock Mechanics and Mining Sciences*, Vol. 43, 224–235 (2006).
35. K. Zorlu, C. Gokceoglu, F. Ocakoglu, H.A. Nefeslioglu, S. Acikalin, Prediction of uniaxial compressive strength of sandstones using petrography-based models. *Engineering Geology*, Vol. 96, 141–158 (2008).
36. S. Yagiz, C. Gokceoglu, E. Sezer, S. Iplikci, Application of two non-linear prediction tools to the estimation of tunnel boring machine performance. *Engineering Applications of Artificial Intelligence*, Vol. 22, 808–814 (2009).
37. ASCE Task Committee, Artificial neural networks in hydrology, II: Hydrologic applications. *J. Hydrologic Eng.*, Vol.5, No.2, 124–137 (2000).
38. G. Tayfur, D. Swiatek, A. Wita, P. Singh, A.K. Barton, Case Study: Finite Element Method and Artificial Neural Network Models for Flow through Jeziersko Earthfill Dam in Poland. *Journal of Hydraulic Engineering-ASCE*, Vol. 131, No. 6, 431–440 (2005).
39. M. Negnevitsky, *Artificial Intelligence: A Guide to Intelligent Systems*, Addison-Wesley, England (2002).
40. M.H. Hassoun, *Fundamentals of Artificial Neural Networks*, MIT Press, Cambridge, MA (1995).
41. C.W. Dawson, R. Wilby, An artificial neural network approach to rainfall-runoff modelling. *Hydrological Sciences journal* 43 (1), 47–66 (1998).
42. S. Haykin, *Neural Networks a Comprehensive Foundation*, MacMillan, New York (1994).
43. T. Munakata, *Fundamentals of the New Artificial Intelligence: Beyond Traditional Paradigms*, Springer-Verlag, New York (1998).

Klazomenai, one of the twelve ancient Ion cities, is very close to the structure where the limestone was obtained for this work. Klazomenai was cited by the famous historian Herodotus Halikarnasus (484-425 BC). Klazomenai has the second oldest olive oil factory in the world. Limestone similar to the ones analyzed in this work was used in the construction of Klazomenai ancient city and ancient olive oil factory. Due to conservation purposes, it is impossible to remove the stones of the ancient city or ancient factory for testing. The researchers can use the models in this work to relate the mechanical properties of limestone for the ancient city Klazomenai and ancient olive oil factory.

Limestone is a common construction material used in many historical masonry structure. Moreover, it has been used in constructions of retaining walls, earth supporting structures, highway foundations and masonry buildings in all over the world. Above all, limestone is used in production of cement, the principal component of concrete and mortar. Hence the models developed in this study can be used by the researchers and field engineers in estimation of mechanical properties of limestone.

## Acknowledgement

We would like to thank The Scientific and Technical Research Council of Turkey (TUBITAK), for funding of the project ICTAG I-591.