



CLEVERBROKER

SYSTEM DOBORU GRACZY ESPORTOWYCH
OPARTY O ROZWIĄZANIA W ZAKRESIE
SZTUCZNEJ INTELIGENCJI

RAPORT Z PRAC BADAWCZYCH
LIPIEC 2020 - KWIECIEŃ 2021

Aleksander Kaim
kierownik prac badawczo rozwojowych
T +48730366677, E alek@emine.pro

Spis Treści

1. Dane firmy	8
2. Informacje o projekcie	8
Tabela 1: Poziomy gotowości technologicznej, etapy prac B+R	9
3. Raport z realizacji projektu B+R	10
3.1. Start projektu: wyłonienie zestawu cech i wartości do badania w kolejnych etapach projektu	10
Tabela 1: Fragment bazy graczy I etapu i decyzje o ich poziomie oparte na trójstopniowej skali	12
Tabela 2: Mierzalne cechy zawodnika esportowego, które posłużą do dalszych badań	13
3.2. Wyłonienie modelu klasyfikującego uczenia maszynowego	22
Rysunek 1: Fragment widoku bazy danych – szczegółowe statystyki graczy podczas wielu rozgrywek.	23
Rysunek 2: Fragment widoku bazy danych – uśrednione statystyki graczy z wielu rozgrywek.	24
Rysunek 3: Fragment widoku zbioru danych – zestawienie cech obu drużyn z informacją kto wygrał potyczkę (ang. winner).	25
Rysunek 4: Lista badanych algorytmów uczenia maszynowego – zawiera wyniki w postaci precyzji	25
Rysunek 5: Widok celu (kto zwycięży mecz) algorytmów uczenia maszynowego.	26
Rysunek 6: Wybrana metryka – precyzja – (ang. Accuracy) do oceny jakości klasyfikacji.	26



Rysunek 7: Lista badanych algorytmów uczenia maszynowego – zawiera wyniki w postaci precyzji (ang. Accuracy).	27
Tabela 8: Krzywa uczenia – wpływ ilość danych uczących na przewidywany stopień precyzji predykcji dwóch przykładowych algorytmów uczenia maszynowego.	28
Rysunek 9: Lista badanych algorytmów uczenia maszynowego – zawiera wyniki w postaci precyzji (ang. Accuracy).	28
Rysunek 10: Wynik badanych algorytmów uczenia maszynowego - min-max rescaling.	30
Rysunek 11: Wynik badanych algorytmów uczenia maszynowego – avg-std rescaling.	30
Rysunek 12: Wynik badanych algorytmów uczenia maszynowego – no rescaling.	31
Rysunek 13: Widok ważności cechy w kontekście predykcji wygranej – wszystkie cechy.	32
Rysunek 14: Widok ważności cechy w kontekście predykcji wygranej – z pominięciem cech z przedrostkiem „rounds”	33
Rysunek 15: Widok korelacji cechy avg_rating (ocena eksperta dziedzinowego) w stosunku do przebadanych cech. Zielone obramowanie wyróżnia kilka spośród najważniejszych charakterystyk, wytypowanych przez algorytm uczenia maszynowego.	34
Rysunek 16: Wzór na wartość etykiety rekrutacyjnej - Player Power	35
Rysunek 17: Fragment widoku bazy danych – ewaluacja graczy na podstawie etykiety rekrutacyjnej	35
Rysunek 18: Fragment widoku bazy graczy zawierający podstawowe informacje i ocenę trenerską	36
Rysunek 19: Fragment widoku bazy graczy zawierający widok trenera służący do oceny zawodnika	37
Rysunek 20: Fragment widoku bazy graczy zawierający statystyki przykładowego spotkania	37



3.3. Porównanie systemu wyszukiwania drużyn AI do klasyfikatora

eksperckiego. 38

Rys 1. Fragment bazy danych zawierający informacje opisujące danego gracza w danym meczu. 38

Rys 2. Fragment danych zawodników przetransformowanych do postaci średnich drużyn „t1” i „t2”, czyli drużyna 1 i drużyna 2. 39

Rys 3. Parametry punktu API umożliwiają dobranie danych wejściowych. 39

Rys 4. Każda drużyna rozgrywająca mecze w sezonie 2 #ARMY otrzymuje procentową predykcję szansy na wygraną wygenerowaną przez algorytm AI (kolumna „AI PRED.”) 39

Rys 5. Pierwsze 2 kolejki drabinki wygranych w 2 sezonie projektu #ARMY, wraz z predykcjami trenerów oraz AI. 40

Rys 6. Pierwsze 2 kolejki drabinki przegranych w 2 sezonie projektu #ARMY, wraz z predykcjami trenerów oraz AI. 40

3.4 AI wskazuje conajmniej jedną drużynę, która uzyska wysokie

miejsce w turnieju. 41

Rys. 1, 2, 3 i 4 Wybrane widoki interfejsów ułatwiających przeprowadzenie badań psychologicznych. 41

Rys. 5 i 6 Wybrane widoki interfejsów ułatwiających przeprowadzenie badań dietetycznych. 42

Rys. 7 Panel laboratorium – umożliwia tworzenie drużyn z dostępnych zawodników 43

Rys. 8 Panel lobby – umożliwia drużynom synchronizację gotowości do rozegrania meczu 44

Rys. 9 Panel lobby wariant 2 – umożliwia drużynom wybranie docelowej mapy 44



Rys. 10 Panel lobby wariant 3 – widok informujący o utworzeniu meczu wraz z lokalizacją serwera na którym odbędzie się rozgrywka 45

Rys. 11 Zrzut ekranu z bazy foto z rozgrywek LAN w Netto Arena w Szczecinie 46

3.5 Do systemu wprowadzone zostaną nowe cechy/system wskazuje przynajmniej jedną drużynę, która osiągnęła wysokie miejsce w turnieju. 47

Rys. 1 Fragment widoku danych z badań psychologicznych – w formie arkusza kalkulacyjnego. 47

Rys. 2 Fragment widoku bazy danych – dane z badań psychologicznych. 48

Rys. 3 Fragment widoku danych z badań dietetycznych – w formie arkusza kalkulacyjnego. 48

Rys. 4 Fragment widoku bazy danych – dane z badań dietetycznych. 49

Rys. 5 Wzór na wartość etykiety rekrutacyjnej - Player Power. 49

Rys. 6 Fragment widoku bazy danych – zestawienie cech psychologicznych w połączeniu z etykietą rekrutacyjną (Player Power). 50

Rys. 7 Lista badanych algorytmów uczenia maszynowego – zawiera wyniki badania danych psychologicznych w postaci współczynnika determinacji (ang. R2 score). Cel badania: przewidzenie wartości etykiety rekrutacyjnej (PP). 50

Rys. 8 Lista badanych algorytmów uczenia maszynowego – zawiera wyniki badania danych dietetycznych w postaci współczynnika determinacji (ang. R2 score). Cel badania: przewidzenie wartości etykiety rekrutacyjnej (PP). 51

Rys. 9 Fragment widoku zbioru danych – zestawienie cech psychologicznych oraz roli jaką pełnią gracze. Następnie, do procesu uczenia modeli AI, dobraliśmy graczy o najwyższym PP (Player 52



Rys. 10 Lista badanych algorytmów uczenia maszynowego – zawiera wyniki przewidywania roli gracza w postaci precyzji (ang. Accuracy).	53
Rys. 11 Wybrana metryka - precyzja (ang. Accuracy) - do oceny jakości klasyfikacji.	53
Rys. 12 Widok celu (roli – AWP lub Rifler) algorytmów uczenia maszynowego.	54
Rys. 13 Lista badanych algorytmów uczenia maszynowego – zawiera wyniki przewidywania stopnia refleksu gracza w postaci współczynnika determinacji (ang. R2 score).	55
Rys. 14 Korelacje zmiennej aktywność fizyczna.	55
Rys. 15 Korelacje zmiennej jakość diety.	56
Rys. 16 Korelacje zmiennej nawyki żywieniowe.	56

3.6 Zaprezentowanie zestawu cech, który daje najlepsze drużyny esportowe.

Rys. 1 Panel zawodników - widok kart z najistotniejszymi cechami graczy.	58
Rys. 2 Panel zawodnika - szczegółowy widok charakterystyk gracza.	58
Rys. 3 Esportowe CV gracza.	60
Rys. 4 Panel zawodników – widok tabelaryczny – dostępny tylko dla trenerów.	60
Rys. 5 Panel zawodników – widok ocen wystawianych przez algorytmy uczenia maszynowego.	61
Rys. 6 Panel trenerów – widok ocen wystawianych trenerom przez graczy.	62
Rys. 7 Panel drużyn - widok kart z najistotniejszymi cechami składów.	63
Rys. 8 Panel drużyny - szczegółowy widok charakterystyk i członków zespołu.	63



Rys. 9 Panel drużyn - widok tabelaryczny – dostępny tylko dla trenerów.	
65	
Rys. 10 Panel analiz – widok zbiorczy z punktu widzenia gracza.	66
Rys. 11 Panel analiz – widok wykonanej analizy z punktu widzenia gracza.	
66	
Rys. 12 Panel analiz tekstowych – widok tabelaryczny z punktu widzenia trenera.	67
Rys. 13 Panel analiz tekstowych - widok edycji z punktu widzenia trenera.	
67	
Rys. 14 Panel analiz map - widok tabelaryczny z punktu widzenia trenera.	
68	
Rys. 15 Panel analiz map - widok edycji z punktu widzenia trenera.	68
Rys. 16 Czat drużynowy – widok z punktu widzenia graczy – umożliwia przesyłanie komunikatów od trenerów do całych drużyn oraz komunikacje między członkami drużyny.	68
Rys. 17 Czat indywidualny – widok z punktu widzenia każdego typu użytkownika (np. gracz, trener) – umożliwia przesyłanie komunikatów pomiędzy wszystkimi użytkownikami platformy arrMY.	69
Rys. 18 Panel ocen zawodników – widok z punktu widzenia trenera.	70
Rys. 19 Panel ocen zawodników – edycja notatki z punktu widzenia trenera.	
70	
Rys. 20 Panel testy – widok testu badającego osobowość gracza.	71
Rys. 21 Panel testy – widok wyniku badania osobowości gracza.	72
3.7 System doboru graczy przechodzi beta testy.	72



1. Dane firmy

CleverBroker Spółka z Ograniczoną Odpowiedzialnością Spółka Komandytowa
ul. Słoneczny Sad
72-002 Dołuje, Polska
NIP: 8513242913
KRS 0000810994

2. Informacje o projekcie

Realizowany projekt ma na celu opracować model połączenia różnych metod uczenia maszynowego, które doprowadzi do stworzenia wielopłaszczyznowego systemu informatycznego opartego o sztuczną inteligencję, której zadaniem będzie weryfikacja oraz profesjonalizacja graczy esportowych i ułatwienie procesu doboru zawodników do drużyn. Dzięki implementacji do systemu sztucznej inteligencji narzędzie będzie samo się usprawniało np.: poprzez dodanie nowych wymiarów i parametrów. Opracowanie tego nowoczesnego systemu będzie wypadkową współpracy badaczy. Będzie to pierwszy tak złożony oraz wielokryterialny system wykorzystywany na potrzeby e-sportu na świecie.

Projekt tworzą pracownicy firmy CleverBroker, którzy realizują działania w obszarach projektu nazwanego ARRM, który jest projektem esportowym opartym na wiedzy z zakresu esportu, oraz zespół programistów, skupiających się na zautomatyzowaniu działań trenerów oraz implementacji systemu uczenia maszynowego w proces doboru i oceny graczy. Zespół ekspertów esportowych składa się z:

Jakub Kubiak: specjalista z zakresu oceniania obiektów/drużyn

Marcin Klusek: pomocnik w ocenie meczów esportowych - trener

Bartłomiej Gawlas: pomocnik w ocenie meczów esportowych - trener

Jakub Salwa: pomocnik w ocenie meczów esportowych - trener

Zespół programistów natomiast jest tworzony przez:

Paweł Niedzin: kierownik programistów

Justyna Wąchlicka: programista aplikacji backendowych i systemów inteligencji

Paweł Szustakiewicz: specjalista z zakresu PHP/baz danych/javascript



Dodatkowo w projekcie uczestniczą:

Aleksander Kaim: kierownik prac B+R

Bartosz Polender: koordynator prac B+R

Projekt realizowany jest z podziałem na 8 okresów. Każdy z nich zakończony jest kamieniem milowym, którego zrealizowanie determinuje dalsze kontynuowanie prac. Poniższa tabela przedstawia kluczowe dla każdego z okresu kamienie milowe:

Tabela 1: Poziomy gotowości technologicznej, etapy prac B+R

Wyłonienie zestawu cech i wartości do badania w kolejnych etapach projektu.	II
Wyłonienie modelu klasyfikującego uczenia maszynowe.	III
Porównanie systemu wyszukania drużyn AI do klasyfikatora eksperckiego.	IV
AI wskazuje conajmniej jedną drużynę, która uzyska wysokie miejsce w turnieju.	V
Do systemu wprowadzone zostaną nowe cechy/system wskazuje przynajmniej jedną drużynę, która osiągnęła wysokie miejsce w turnieju.	VI
Zaprezentowanie zestawu cech, który daje najlepsze drużyny esportowe	VII
System doboru graczy przechodzi beta testy.	VIII

Niniejszy dokument jest raportem z realizacji postępu prac B+R. Każdy z poniższych rozdziałów opisuje prace wykonane w każdym z etapów oraz dokumentuje najważniejsze wnioski. Etapy prac zostały podzielone na rozdziały. Każdy kończy się wnioskami i rekomendacjami do dalszych działań.



3. Raport z realizacji projektu B+R

Niniejszy dokument jest raportem z realizacji postępu prac B+R. Każdy z poniższych rozdziałów opisuje prace wykonane w każdym z etapów oraz dokumentuje najważniejsze wnioski. Etapy prac zostały podzielone na rozdziały. Każdy kończy się wnioskami i rekomendacjami do dalszych działań.

3.1. Start projektu: wyłonienie zestawu cech i wartości do badania w kolejnych etapach projektu

Start projektu poprzedzony był zintegrowanymi działaniami marketingowymi opartymi o influence marketing i kampanie nastawioną na dotarcie do hermetycznej grupy odbiorców docelowych - osoby levelu semi pro w grze Counter Strike: Global Offensive. Takie mocne działania były wymuszone chęcią uzyskania dużej grupy badawczej, która ma stanowić później o wyniku całego projektu. Ogłoszenie naborów do ARMY, czyli projektu mającego oceniać graczy i doprowadzić ich do pierwszych kontraktów spotkało się z aprobatą społeczności, co zaowocowało 1028 osobami, które zadeklarowały chęć przystąpienia do projektu w charakterze gracza/badanego obiektu. Każdy z uczestników przystępujących do I etapu projektu otrzymał termin spotkania, na którym stawiając się podlegał eksperckiej ocenie trenerów koordynatorów. Trenerzy określili swoje kryteria ocen, które opierały się na 3 charakterystykach nadrzędnych:

a) UMIEJĘTNOŚCI KOMUNIKACYJNE

b) UMIEJĘTNOŚCI STRZELECKIE

c) UMIEJĘTNOŚĆ GRY DRUŻYNOWEJ

W każdym z tych obszarów o finalnej ocenie decydowały składowe:

UMIEJĘTNOŚCI KOMUNIKACYJNE

- informacje przekazywane partnerom z drużyny w czasie rzeczywistym (gracz przekazuje informacje o swojej pozycji, sprawnie informuje o pozycji dostrzeżonego rywala, zwięźle informuje o swoich ruchach i decyzjach, nie wprowadza niepotrzebnego haosu poprzez niepotrzebne komunikaty)
- planowanie najbliższych rund przed ich rozegraniami (umiejętne określanie swoich akcji w oparciu o planowanie ruchów graczy z drużyny przeciwnej, w niektórych sytuacjach ma to także miejsce w trakcie rundy - wysoka ocena w tym obszarze może decydować o przyznaniu rangi „prowadzącego”, czyli osoby decydującej o taktykach przed rundami)



- sposób przekazywania informacji (spokojne informowanie, brak skrajnych emocji, odpowiednia intonacja, przekazywanie precyzyjnie i głośno kluczowych komunikatów)

UMIEJĘTNOŚCI STRZELECKIE

- umiejętność trzymania przeciwnika na linii precyzyjnego strzału (wymaga dużych umiejętności manualnych, precyzji i wyłapania ruchów na mapie oraz obrania celu na głowę, w której trafienie eliminuje rywala najszybciej) / crosshair placement
- znajomość i wyczucie pozycji, których zajęcie daje przewagę strategiczną nad rywalem w planach przed rundami, wskazanie na swoje decyzje / teoria
- realizacja zajęć taktycznych ustalonych przed rundą w oparciu o sytuacje w czasie rozgrywki i ruchy przeciwników / praktyka

UMIEJĘTNOŚĆ GRY DRUŻYNOWEJ

- umiejętność i precyzyjne planowanie działań w rundach / prowadzenie narad przed rundą, skuteczne planowanie
- zarządzanie poczynaniami osób w czasie rozgrywki / dowodzenia
- dostosowywanie działań drużyny w oparciu o wyłapywanie planów taktycznych rywali

I etap rekrutacji wyłaniał zawodników, którzy nie spełniali większości ocen w stopniu minimalnym. Miał on na celu wyłapanie osób, które nie mogą zostać wprowadzone do systemu uczenia maszynowego ze względu na nich niedostateczną wiedzę i obecny poziom. Zastosowano wnikliwą ocenę i trzy kryteria oceny, gdzie skrajnie decydowały o przejściu do kolejnego etapu rekrutacji, a środkowe dawały uczestnikom kolejną szansę, podczas której mogli wykazać postęp i otrzymać dalszy awans. Oceny były dawane podczas meczów, które składały się z 3 map, czyli rozgrywek do 16 wygranych rund przez jedną z drużyn. Drużyny były tworzone przez trenerów w oparciu o informacje o ulubionych pozycjach jakie wskazywali uczestnicy badania. Finalnie do projektu przystąpiło, czyli zatwierdziło i rozegrało mecz weryfikacyjny 653 osoby z których 181 zostało odrzuconych, a 472 przeszło dalej. Poniższy wykres ilustruje bazę zawodników po I etapie i decyzje o ich otrzymaniu promocji do kolejnego etapu. Pełna baza dostępna jest w chmurze Google, dostępna pod adresem: <https://docs.google.com/spreadsheets/d/1iS4fV8maQejVHsD396pK7LYU8EDLv-BLAQbyc08e0s8/edit?ts=5fa6a319#gid=0>



Tabela 1: Fragment bazy graczy I etapu i decyzje o ich poziomie oparte na trójstopniowej skali

TRENER - INWOOD				TRENER - KUBIK				TRENER - KUBIK				
		POTWIERDZENIE	ZMIANA	STEAM		POTWIERDZENIE		POTWIERDZENIE	ZMIANA	STEAM		
IGL	ncw0711	ok	x	tak	IGL	wicior	ok	IGL	Poplawski17	OK	x	TAK
AWP	Luxon27	ok	x	tak	AWP	yungshadow	ok	AWP	axm32	OK	x	TAK
RIFFLER	CzyszcZan	ok	x	tak	RIFFLER	Jareoc	ok	RIFFLER	Pelle100xD	ok	x	TAK
RIFFLER	Mafez	ok	x	tak	RIFFLER	wITr0xU	ok	RIFFLER	mikalelelee	ok	x	TAK
RIFFLER	golden	ok	x	tak	RIFFLER	Borewicz398	ok	RIFFLER	Jano1337	ok	x	TAK
IGL	garbus0502	ok	x	tak	IGL	krawatkład	ok	IGL	Anus	ok	x	TAK
AWP	VimiXen	ok	x	tak	AWP	Wajchusz	ok	AWP	costa1g	ok	x	TAK
RIFFLER	kaem	ok	x	tak	RIFFLER	PRESCIĄK	ok	RIFFLER	Kuba1305	ok	x	TAK
RIFFLER	COMEATMEBRO	ok	x	tak	RIFFLER	alicjastart	ok	RIFFLER	davE	ok	x	TAK
RIFFLER	evil	ok	x	tak	RIFFLER	neqo	ok	RIFFLER	rybadigital	ok	x	TAK
TRENER - BGG				TRENER - BGG				TRENER - KUBIK				
		POTWIERDZENIE	ZMIANA	STEAM		POTWIERDZENIE		POTWIERDZENIE	ZMIANA	STEAM		
IGL	Pokemob	ok	x	tak	IGL	For3x	ok	IGL	Hezz	ok		TAK
AWP	Zefir	ok	x	tak	AWP	kubba003	ok	AWP	SYXZJAE	ok		TAK
RIFFLER	Dawidos	ok	x	tak	RIFFLER	Kaymee	ok	RIFFLER	ven	ok		tak
RIFFLER	brajt	ok	x	tak	RIFFLER	killtronic	ok	RIFFLER	Fineash	ok		TAK
RIFFLER	ScAnIX	ok	x	tak	RIFFLER	TomSon	ok	RIFFLER	yamareg	ok		TAK
IGL	EL Drapko	ok	x	tak	IGL	krez	ok	IGL	DigKing	ok		tak
AWP	benstygDd	ok	x	tak	AWP	muminek234	ok	AWP	dem0niz	OK		TAK
RIFFLER	TicQ	ok	x	tak	RIFFLER	kieroo	ok	RIFFLER	wysek091	ok		TAK
RIFFLER	Fizer	ok	x	tak	RIFFLER	Pulsefire	ok	RIFFLER	Sarox	ok		TAK
RIFFLER	Klusek	ok	x	tak	RIFFLER	emte	ok	RIFFLER	Zarshu	ok		TAK

Po wyłonieniu uczestników II etapu projekt został kontynuowany w niezmienny sposób, jednak przy większej szczegółowości oceny oraz innym otoczeniu. Po odpadnięciu osób nieporządkanych, zaniżających możliwości prowadzenia zaawansowanej gry drużynowej, poziom meczów się podniósł i dało to zawodnikom możliwość do większego wykazania się swoimi umiejętnościami.

W czasie gdy trenerzy przeprowadzali proces wyboru graczy programiści pracowali nad panelem informatycznym służącym do lepszego zarządzania projektem oraz przy współpracy z trenerami określali zestaw cech i wartości, które będą badane na dalszych etapach. Został utworzony program zintegrowany z serwisem #ARMY, który pobiera wszystkie pliki demo dotychczas rozegranych spotkań - na dzień 4 sierpnia było to 251 plików o łącznej wadze 21.1GB. Program może pobierać dane zarówno na serwer projektu jak również lokalne komputery developerów. Program jest odporny na zrywanie połączenia czy inne ewentualne problemy, które mogą się pojawić podczas pobierania pliku demo – będzie on próbował pobrać dane do skutku. Podczas prac stwierdzone zostało, że istnieje problem połączenia graczy z plików demo z użytkownikami #ARMY. W plikach demo jest zapis identyfikatora steamID2, oraz steamID64 dla każdego z graczy, natomiast w serwisie #ARMY posiadamy link do profilu Steam w 2 formatach w zależności od tego jak podał go użytkownik:

- <https://steamcommunity.com/profiles/76561198821672795>
- <https://steamcommunity.com/id/c0rV/>

Pierwszy format w ostatniej części linku zawiera identyfikator SteamID64, który umożliwia identyfikację, którym użytkownikiem serwisu #ARMY jest dany gracz, natomiast drugi format już



nie daje takiej możliwości – „nickname” gracza w grze może różnić się znacząco od tego jakim posługuje się w serwisie #ARMY. W związku z tym problemem napisany został program zintegrowany z serwisem #ARMY, który automatycznie przerabia oba rodzaje linków do steamID2 i zapisuje to w bazie danych. Program został napisany przy pomocy narzędzia xPaw/SteamID, oraz SteamAPI.

Finałem działań i zarazem realizacją kamienia milowego było wyłonienie cech i stworzenie parsera, który analizuje pliki demo pod kątem nawet 330 cech łącznie. Poniższa tabela przedstawia cechy, które posłużą do dalszych badań:

Tabela 2: Mierzalne cechy zawodnika esportowego, które posłużą do dalszych badań

Nazwa cechy	Opis cechy
map	Nazwa mapy, na której było rozgrywane spotkanie
max_rounds	Ilość rund w spotkaniu
half_score_t	Wynik terrorystów do przerwy
half_score_ct	Wynik antyterrorystów do przerwy
score_t	Wynik terrorystów na koniec meczu
score_ct	Wynik antyterrorystów na koniec meczu
duration	Czas trwania meczu
name	Pseudonim gracza używany w grze CS:GO
steamid2	Identyfikator Steam gracza, który będzie używany do połączenia go z użytkownikiem z serwisu #ARMY
alive alive_t alive_ct	Rzeczywisty czas życia gracza. Liczymy tutaj tylko czas kiedy zawodnik faktycznie gra – bez żadnych przerw
rounds_t rounds_ct	Ilość rozegranych rund po stronie terrorystów, oraz antyterrorystów
rounds_won_t rounds_won_ct	Ilość wygranych rund po stronie terrorystów, oraz antyterrorystów
damage damage_t damage_ct	Ilość obrażeń zadanych przez gracza
adr	Średnia ilość obrażeń na rundę (Average Damage Round)



damage_received damage_received_t damage_received_ct	Ilość obrażeń otrzymanych przez gracza
grenade_damage grenade_damage_t grenade_damage_ct	Ilość obrażeń zadanych granatami (grant zapalający, odłamkowy) przez gracza
grenade_adr	Średnie ilość obrażeń zadanych granatami na rundę
kills kills_t kills_ct	Ilość zabójstw
assists assists_t assists_ct	Ilość asyst
deaths deaths_t deaths_ct	Ilość śmierci
headshots headshots_t headshots_ct	Ilość zabójstw strzałem w głowę
no_scope_kills no_scope_kills_t no_scope_kills_ct	Ilość zabójstw z broni snajperskiej (AWP) bez użycia przybliżenia
flashed_kills flashed_kills_t flashed_kills_ct	Ilość zabójstw kiedy atakujący jest oślepiiony granatem oślepiającym
flash_assists flash_assists_t flash_assists_ct	Ilość asyst za pomocą granatu oślepiającego
flashed_deaths flashed_deaths_t flashed_deaths_ct	Ilość śmierci kiedy gracz jest oślepiiony granatem oślepiającym
kills_unequiped kills_unequiped_t kills_unequiped_ct	Ilość zabójstw kiedy ofiara nie posiada broni w rękach
deaths_unequiped deaths_unequiped_t deaths_unequiped_ct	Ilość śmierci kiedy gracz nie posiada broni w rękach
awp_kills awp_kills_t awp_kills_ct	Ilość zabójstw z użyciem broni snajperskiej AWP



awp_deaths awp_deaths_t awp_deaths_ct	Ilość śmierci kiedy gracz posiada broń snajperską w rękach
awp_scoped_won awp_scoped_won_t awp_scoped_won_ct	Ilość wygranych pojedynków kiedy obu graczy posiada broń snajperską AWP i jest w trybie przybliżenia
awp_scoped_lose awp_scoped_lose_t awp_scoped_lose_ct	Ilość przegranych pojedynków kiedy obu graczy posiada broń snajperską AWP i jest w trybie przybliżenia
post_plant_kills post_plant_kills_t post_plant_kills_ct	Ilość zabójstw w sytuacji kiedy została podłożona bomba
post_plant_deaths post_plant_deaths_t post_plant_deaths_ct	Ilość śmierci w sytuacji kiedy została podłożona bomba
trade_kills trade_kills_t trade_kills_ct	Ilość zabójstw na graczu, który do 3 sekund wcześniej zabił kolegę z drużyny
traded_deaths traded_deaths_t traded_deaths_ct	Ilość śmierci kiedy gracz został zabity do 3 sekund po zabiciu innego gracza z przeciwnej drużyny
2K 2K_t 2K_ct	Ilość rund, w których gracz zdobył 2 zabójstwa
3K 3K_t 3K_ct	Ilość rund, w których gracz zdobył 3 zabójstwa
4K 4K_t 4K_ct	Ilość rund, w których gracz zdobył 4 zabójstwa
5K 5K_t 5K_ct	Ilość rund, w których gracz zdobył 5 zabójstw
opening_kills opening_kills_t opening_kills_ct	Ilość rund w których gracz zdobył 1 zabójstwo w rundzie
opening_deaths opening_deaths_t opening_deaths_ct	Ilość rund w których gracz zginął jako pierwszy w rundzie



kills_not_seeing kills_not_seeing_t kills_not_seeing_ct	Ilość zabójstw na graczach, którzy nie widzieli zabójcy
deaths_not_seeing deaths_not_seeing_t deaths_not_seeing_ct	Ilość śmierci kiedy gracz nie widzi zabójcy
1vs1 1vs1_t 1vs1_ct	Ilość sytuacji 1 na 1 w których znalazł się gracz
1vs2 1vs2_t 1vs2_ct	Ilość sytuacji 1 na 2 w których znalazł się gracz
1vs3 1vs3_t 1vs3_ct	Ilość sytuacji 1 na 3 w których znalazł się gracz
1vs4 1vs4_t 1vs4_ct	Ilość sytuacji 1 na 4 w których znalazł się gracz
1vs5 1vs5_t 1vs5_ct	Ilość sytuacji 1 na 5 w których znalazł się gracz
1vs1_won 1vs1_won_t 1vs1_won_ct	Ilość sytuacji 1 na 1 wygranych przez gracza
1vs2_won 1vs2_won_t 1vs2_won_ct	Ilość sytuacji 1 na 2 wygranych przez gracza
1vs3_won 1vs3_won_t 1vs3_won_ct	Ilość sytuacji 1 na 3 wygranych przez gracza
1vs4_won 1vs4_won_t 1vs4_won_ct	Ilość sytuacji 1 na 4 wygranych przez gracza
1vs5_won 1vs5_won_t 1vs5_won_ct	Ilość sytuacji 1 na 5 wygranych przez gracza
bomb_plants	Ilość podłożonych bomb przez gracza
bomb_defuses	Ilość rozbrojonych bomb przez gracza



avg_first_contact avg_first_contact_t avg_first_contact_ct	Średni czas do pierwszego kontaktu z przeciwnikiem. Pierwszy kontakt to czas do pierwszego bycia zranionym, lub zranienia przeciwnika.
avg_first_see avg_first_see_t avg_first_see_ct	Średni czas do pierwszego zobaczenia przeciwnika.
reactions_time_ms reactions_time_ms_t reactions_time_ms_ct	Suma czasów reakcji. W połączeniu z reactions_amount tworzy średni czas reakcji
reactions_amount reactions_amount_t reactions_amount_ct	Ile razy zareagował gracz
blind_to_enemy_amount blind_to_enemy_amount_t blind_to_enemy_amount_c	Ile razy gracz oślepił przeciwnika
blind_to_enemy_duration blind_to_enemy_duration_t blind_to_enemy_duration_ct	Ile czasu przeciwnicy byli oślepieni przez gracza
blind_by_enemy_amount blind_by_enemy_amount_t blind_by_enemy_amount_ct	Ile razy gracz został oślepiony przez przeciwników
blind_by_enemy_duration blind_by_enemy_duration_t blind_by_enemy_duration_ct	Ile czasu gracz był oślepiony przez przeciwników
blind_to_team_amount blind_to_team_amount_t blind_to_team_amount_ct	Ile razy gracz oślepił kolegów z drużyny
blind_to_team_duration blind_to_team_duration_t blind_to_team_duration_ct	Ile czasu koledzy z drużyny byli oślepieni przez gracza
blind_by_team_amount blind_by_team_amount_t blind_by_team_amount_ct	Ile razy gracz został oślepiony przez kolegów z drużyny
blind_by_team_duration blind_by_team_duration_t blind_by_team_duration_c	Ile czasu gracz był oślepiony przez kolegów z drużyny



steps steps_t steps_ct	Ilość głośnych kroków zrobionych przez gracza.
steps_first_10_sec steps_first_10_sec_t steps_first_10_sec_ct	Ilość głośnych kroków zrobionych przez gracza w ciągu pierwszych 10 sekund rundy
distance distance_t distance_ct	Dystans przebyty przez gracza
distance_first_10_sec distance_first_10_sec_t distance_first_10_sec_ct	Dystans przebyty przez gracza w ciągu pierwszych 10 sekund rundy
has_bomb_sec	Ile czasu gracz posiadał ładunek wybuchowy
has_awp_sec has_awp_sec_t has_awp_sec_ct	Ile czasu gracz posiadał broń snajperską AWP
hlvtv_kast hlvtv_kast_t hlvtv_kast_ct	Ilość rund, w których gracz zabił, lub miał asystę, lub przeżył, lub został pomszczony w ciągu 3 sekund od swojej śmierci
shoots_fired_on_see shoots_fired_on_see_t shoots_fired_on_see_ct	Ilość strzałów wystrzelonych kiedy gracz widział przynajmniej jednego przeciwnika
shoots_hurt_on_see shoots_hurt_on_see_t shoots_hurt_on_see_ct	Ilość strzałów trafionych kiedy gracz widział przynajmniej jednego przeciwnika
shoots_fired shoots_fired_t shoots_fired_ct	Ilość strzałów wystrzelonych przez gracza
shoots_hurt shoots_hurt_t shoots_hurt_ct	Ilość strzałów trafionych przez gracza
flicks_made flicks_made_t flicks_made_ct	Ile razy gracz wykonał szybki obrót myszką (min. 5 stopni) i zabił pierwszymi 2 strzałami przeciwnika
flicks_made_awp flicks_made_awp_t flicks_made_awp_ct	Ile razy gracz wykonał szybki obrót myszką (min. 5 stopni) i zabił przeciwnika za pomocą broni snajperskiej AWP w trybie przybliżenia
exit_kills exit_kills_t exit_kills_ct	Ilość zabójstw po nieoficjalnym zakończeniu rundy. Oficjalne zakończenie ma miejsce kilka sekund później.



exit_deaths exit_deaths_t exit_deaths_ct	Ilość śmierci po nieoficjalnym zakończeniu rundy. Oficjalne zakończenie ma miejsce kilka sekund później.
dmg_hitgroup_generic dmg_hitgroup_generic_t dmg_hitgroup_generic_ct	Ilość obrażeń generycznych zadanych przez gracza. Obrażenia generyczne to obrażenia całego ciała np. od granatu odłamkowego
dmg_hitgroup_head dmg_hitgroup_head_t dmg_hitgroup_head_ct	Ilość obrażeń w głowę zadanych przez gracza.
dmg_hitgroup_chest dmg_hitgroup_chest_t dmg_hitgroup_chest_ct	Ilość obrażeń w klatkę piersiową zadanych przez gracza.
dmg_hitgroup_stomach dmg_hitgroup_stomach_t dmg_hitgroup_stomach_ct	Ilość obrażeń w brzuch zadanych przez gracza.
dmg_hitgroup_leftarm dmg_hitgroup_leftarm_t dmg_hitgroup_leftarm_ct	Ilość obrażeń w lewą rękę zadanych przez gracza.
dmg_hitgroup_rightarm dmg_hitgroup_rightarm_t dmg_hitgroup_rightarm_ct	Ilość obrażeń w prawą rękę zadanych przez gracza.
dmg_hitgroup_leftleg dmg_hitgroup_leftleg_t dmg_hitgroup_leftleg_ct	Ilość obrażeń w lewą nogę zadanych przez gracza.
dmg_hitgroup_rightleg dmg_hitgroup_rightleg_t dmg_hitgroup_rightleg_ct	Ilość obrażeń w prawą nogę zadanych przez gracza.
rounds_with_kill rounds_with_kill_t rounds_with_kill_ct	Ilość rund, w których gracz miał przynajmniej jedno zabójstwo
total_time_to_kill_sec total_time_to_kill_sec_t total_time_to_kill_sec_ct	Ilość czasu do pierwszego zabójstwa
rounds_with_death rounds_with_death_t rounds_with_death_ct	Ilość rund, w których gracz zginął
total_time_to_death_sec total_time_to_death_sec_t total_time_to_death_sec_c	Ilość czasu do śmierci



kills_distance kills_distance_t kills_distance_ct	Średni dystans do przeciwników, których zabił gracz
deaths_distance deaths_distance_t deaths_distance_ct	Średni dystans do przeciwników, od których zginął gracz
close_distance_kills close_distance_kills_t close_distance_kills_ct	Ilość zabójstw na bliskim dystansie. Do 12 metrów.
close_distance_deaths close_distance_deaths_t close_distance_deaths_ct	Ilość śmierci na bliskim dystansie. Do 12 metrów.
medium_distance_kills medium_distance_kills_t medium_distance_kills_ct	Ilość zabójstw na średnim dystansie. Od 12 do 30 metrów
medium_distance_deaths medium_distance_deaths_t medium_distance_deaths_ct	Ilość śmierci na średnim dystansie. Od 12 do 30 metrów
long_distance_kills long_distance_kills_t long_distance_kills_ct	Ilość zabójstw na dalekim dystansie. Od 30 metrów.
long_distance_deaths long_distance_deaths_t long_distance_deaths_ct	Ilość śmierci na dalekim dystansie. Od 30 metrów.
multi_seeing_kills multi_seeing_kills_t multi_seeing_kills_ct	Ilość zabójstw kiedy gracz widzi ofiarę wraz z przynajmniej jednym kolegą z drużyny
multi_seeing_deaths multi_seeing_deaths_t multi_seeing_deaths_ct	Ilość śmierci kiedy gracz jest widziany przez więcej niż 1 przeciwnika
seeing_enemies_time seeing_enemies_time_t seeing_enemies_time_ct	Ilość czasu jaki gracz widzi się z przeciwnikami
kills_unarmored kills_unarmored_t kills_unarmored_ct	Ilość zabójstw na osobach nie posiadających pancerza
deaths_unarmored deaths_unarmored_t deaths_unarmored_ct	Ilość śmierci kiedy gracz nie posiadał pancerza



kills_dominated kills_dominated_t kills_dominated_ct	Ilość zabójstw więcej niż 1 rundę pod rząd na tym samym graczu
esea_rws esea_rws_t esea_rws_ct	Współczynnik ESEA RWS (esea round win share). https://support.esea.net/hc/en-us/articles/360008740634-What-is-RWS-
pistol_kills pistol_kills_t pistol_kills_ct	Ilość zabójstw z pistoletów
shotgun_kills shotgun_kills_t shotgun_kills_ct	Ilość zabójstw z strzelb
smg_kills smg_kills_t smg_kills_ct	Ilość zabójstw z pistoletów maszynowych
rifle_kills rifle_kills_t rifle_kills_ct	Ilość zabójstw z karabinów
sniper_kills sniper_kills_t sniper_kills_ct	Ilość zabójstw z karabinów snajperskich, oprócz broni AWP, która jest liczona osobno
machine_gun_kills machine_gun_kills_t machine_gun_kills_ct	Ilość zabójstw z karabinów maszynowych
knife_kills knife_kills_t knife_kills_ct	Ilość zabójstw za pomocą noża
grenade_kills grenade_kills_t grenade_kills_ct	Ilość zabójstw granatami
kills_advantage kills_advantage_t kills_advantage_ct	Ilość zabójstw kiedy gracz posiada przewagę broni
deaths_advantage deaths_advantage_t deaths_advantage_ct	Ilość śmierci kiedy gracz posiada przewagę broni

Trenerzy przeprowadzając II etap rekrutacji rozegrali kolejne 75 spotkań, których efektem było odrzucenie kolejnych 178 osób. Do etapu III zaproszone zostały zatem 294 osoby.



REALIZACJA KLUCZOWYCH ZAŁOŻEŃ PROJEKTU B+R ETAPU II CZYLI UTWORZENIE BAZY ZAWODNIKÓW OCENIONYCH PRZEZ TRENERÓW ORAZ OKREŚLENIE ZESTAWU CECH I WARTOŚCI SŁUŻĄCYCH DO BADANIA W KOLEJNYCH ETAPACH POZWALA KONTYNUOWAĆ PROJEKT I PRZEJŚĆ DO KOLEJNEGO ETAPU.

Data realizacji: do 01.09.2020

podpisano: Aleksander Kaim

3.2. Wyłonienie modelu klasyfikującego uczenia maszynowego

Pracę w tym etapie zostały podzielone na obszary zgodne z założonymi kamieniami milowymi:

1. Wyłonienie podstawowych modeli uczenia maszynowego, które można będzie użyć do klasyfikowania zawodników. Następnie na podstawie wyniku analizy danych wejściowych zostaną wybrane najbardziej odpowiednie (przybliżające do celu - czyli wyszukiwarki najlepszych zawodników i drużyn) modele przetwarzania tych danych

1.1. Etapy budowy zbioru uczącego na bazie graczy i rozgrywek z projektu ARRM Y oraz portalu faceit.com

Aby móc zrealizować założenia **etapu III** zostały wykorzystane przedstawione poniżej wyniki prac poprzednich - z **II etapu**:

- programistyczne wygenerowanie wielu statystyk graczy na bazie rozgrywek historycznych – wykorzystano dwa źródła danych: Zawodnicy i mecze z projektu ARRM Y oraz mecze z portalu faceit.com
- stworzenie etykiet umiejętności graczy, zaproponowanych przez osobę fizyczną – trenera z projektu ARRM Y
- stworzenie bazy danych graczy posiadających zestaw wyżej wspomnianych charakterystyk

Dzięki powyższym pracom, stworzono zbiory danych uczących mogące zasilić różne modele uczenia maszynowego w kontekście poszukiwania najlepszych graczy i ich kompozycji, tworzących w konsekwencji najlepsze drużyny.



Na tym etapie prac, głównym celem było w możliwie najefektywniejszy sposób – przybliżający do spełnienia założeń kamieni milowych - połączyć ze sobą dane jakimi dysponujemy podczas prowadzenia projektu ARRM. Ważną kwestią jest to, iż zbiór tych danych rośnie z upływem czasu (zwiększa się liczba graczy i rozgrywek) co w przypadku wykorzystania ich do uczenia maszynowego jest zjawiskiem pożądanym. Im więcej danych tym lepsze predykcje algorytmów (Rys. 8).

1.1.1. Budowa listy zawodników i ich statystyk z wielu meczów

W pierwszej fazie utworzono listę zawodników oraz wszystkich meczy w jakich uczestniczyli. W takiej sytuacji każdy zawodnik został sprofilowany bardzo szczegółowo – występował w bazie w wielu wierszach (Rys. 1).

Rysunek 1: Fragment widoku bazy danych – szczegółowe statystyki graczy podczas wielu rozgrywek.

id	match_map_id	user_id	name	steamid2	alive	damage	alive_t	alive_ct	rounds_t	rounds_ct	rounds_won_t	rounds_won_ct
1576	276	421	ZUCHWINSKYje	STEAM_1:1:115311246	1765.9062500000	1893	864.0781250000	901.83	15	15	6	8
1590	277	421	ZUCHWINSKYje	STEAM_1:1:115311246	1620.3359375000	2433	806.6015625000	813.73	15	15	8	7
1388	246	421	ZUCHWINSKYje	STEAM_1:1:115311246	1445.8203125000	1759	639.0000000000	806.82	15	15	5	5
1396	247	421	ZUCHWINSKYje	STEAM_1:1:115311246	1141.1484375000	1592	531.9062500000	609.24	15	15	5	4
1236	219	421	ZUCHWINSKYje	STEAM_1:1:115311246	1787.4921875000	1776	845.4609375000	942.03	15	15	6	6
1249	220	421	ZUCHWINSKYje	STEAM_1:1:115311246	1522.4531250000	2251	659.1875000000	863.27	15	15	4	4
1260	221	421	ZUCHWINSKYje	STEAM_1:1:115311246	1603.5781250000	1721	952.1484375000	651.43	12	12	6	6
1830	325	96	ZieLuU	STEAM_1:0:32897841	1506.1640625000	1178	872.1640625000	634.00	15	14	7	4
362	72	96	ZieLuU	STEAM_1:0:32897841	1649.4062500000	2701	811.1093750000	838.30	15	15	6	12
380	73	96	ZieLuU	STEAM_1:0:32897841	1892.8359375000	1494	865.1328125000	1027.70	15	15	9	6
663	129	96	ZieLuU	STEAM_1:0:32897841	1585.2968750000	1839	844.0468750000	741.25	15	15	5	4
1688	294	96	ZieLuU	STEAM_1:0:32897841	1636.6875000000	2612	750.0000000000	886.69	15	15	9	5
1694	295	96	ZieLuU	STEAM_1:0:32897841	1684.7890625000	2159	571.6562500000	1113.13	13	15	5	11
677	130	96	ZieLuU	STEAM_1:0:32897841	1509.7968750000	2389	637.3125000000	872.48	15	15	8	6
1730	315	96	ZieLuU	STEAM_1:0:32897841	1816.1484375000	2279	1105.2812500000	710.87	15	15	8	14
2832	485	31	Zefir	STEAM_1:0:103166747	2224.4609375000	1843	1155.2968750000	1069.16	15	15	4	7
2848	486	31	Zefir	STEAM_1:0:103166747	1886.2968750000	2366	1269.3437500000	616.95	15	14	11	6
2176	384	31	Zefir	STEAM_1:0:103166747	1747.3125000000	2791	755.0312500000	992.28	15	15	8	10
1952	347	31	Zefir	STEAM_1:0:103166747	1266.9765625000	1907	673.6484375000	593.33	15	15	9	4
165	40	31	zefir	STEAM_1:0:103166747	2043.7343750000	2897	1256.2812500000	787.45	15	15	9	7

1.1.2. Uśrednienie statystyk graczy z wielu meczów

Następnie wyniki cech z wielu meczy zostały uśrednione (Rys. 2). Dzięki temu otrzymano listę nie dublujących się wierszy/zawodników wraz z interesującymi nas cechami.



Rysunek 2: Fragment widoku bazy danych – uśrednione statystyki graczy z wielu rozgrywek.

id	user_id	alive	alive_t	alive_ct	rounds_t	rounds_ct	rounds_won_t	rounds_won_ct	damage	damage_t
2	9	1778.7650240385	888.9843750000	889.7800000000	14.9231000000	15.0000000000	6.9231000000	7.2308000000	2284.4615000000	1039.076
3	6	1643.5058593750	736.7148437500	906.7912500000	14.8750000000	14.8750000000	6.8750000000	9.3750000000	2626.1250000000	1193.875
4	8	1795.9635416667	898.8242187500	897.1400000000	14.9167000000	14.9167000000	6.7500000000	7.1667000000	2395.5833000000	1113.666
5	12	1731.9479166667	865.9960937500	865.9533330000	14.8333000000	15.1667000000	6.0000000000	6.6667000000	2219.8333000000	903.000
6	14	1582.3593750000	776.1176215278	806.2416670000	14.8889000000	15.0000000000	6.5000000000	7.0556000000	2323.6667000000	1147.555
7	10	1667.1054687500	810.9804687500	856.1250000000	15.5000000000	15.0000000000	5.5000000000	9.0000000000	1802.5000000000	788.000
8	13	1841.8962673611	955.1801215278	886.7155560000	14.8889000000	14.8333000000	6.8333000000	8.8333000000	2312.7778000000	1075.611
9	17	1855.9453125000	930.3515625000	925.5950000000	15.0000000000	15.0000000000	4.5000000000	7.0000000000	2731.0000000000	1308.500
10	15	1948.4531250000	939.3632812500	1009.0900000000	15.0000000000	15.0000000000	8.0000000000	8.0000000000	2374.0000000000	1111.000
11	18	1763.6472355769	835.5727163462	928.0746150000	14.4615000000	14.9231000000	6.8462000000	7.3077000000	2650.1538000000	1184.692
12	16	1965.1541193182	979.2684659091	985.8863640000	14.9091000000	15.0000000000	7.7273000000	7.5455000000	2469.6364000000	1307.909
13	19	1721.7897135417	809.2265625000	912.5633330000	14.3333000000	14.9167000000	6.9167000000	8.4167000000	2234.0833000000	977.083
14	20	1726.6566840278	857.8459201389	868.8100000000	14.7778000000	14.8333000000	8.2778000000	8.5000000000	2504.9444000000	1183.166
15	21	1648.4248046875	828.4628906250	819.9625000000	14.7500000000	14.8750000000	6.2500000000	7.1250000000	2486.1250000000	1229.125
16	23	1656.1757812500	807.4335937500	848.7450000000	15.0000000000	15.0000000000	5.5000000000	4.0000000000	1983.5000000000	908.000
17	24	1806.5535714286	879.8688616071	926.6842860000	14.9286000000	14.9286000000	8.3571000000	8.7143000000	2325.7143000000	959.571
18	25	1774.9892578125	821.7802734375	953.2100000000	14.8750000000	14.8750000000	7.8750000000	6.8125000000	2696.5625000000	1364.125
19	26	1706.3613281250	915.7890625000	790.5725000000	14.7500000000	14.5000000000	7.5000000000	7.7500000000	1995.7500000000	973.000
20	27	1772.5418526786	853.3431919643	914.6264290000	14.2143000000	14.8571000000	7.5714000000	7.5000000000	2258.2143000000	983.285
21	28	1762.9445312500	867.9921875000	894.9530000000	14.9000000000	14.7000000000	7.8000000000	9.6000000000	2441.7000000000	1137.600
22	29	2095.4687500000	994.5664062500	1100.9050000000	15.0000000000	15.0000000000	8.0000000000	8.5000000000	1998.5000000000	814.000
23	30	1883.7414062500	930.0671875000	953.6740000000	15.0000000000	14.9500000000	7.5000000000	8.2500000000	2316.9000000000	1130.300
24	31	1823.9654017857	939.7014508929	884.2628570000	14.5000000000	14.9286000000	7.8571000000	8.2143000000	2615.0714000000	1201.357
25	32	1694.2487980769	771.5576923077	922.6907690000	14.8462000000	14.8462000000	7.3846000000	6.6154000000	2556.9231000000	1212.153
26	33	1830.0265625000	922.9117187500	907.1160000000	15.0000000000	15.0000000000	7.2000000000	6.6000000000	1958.3000000000	966.800
27	34	1700.9804687500	839.5651041667	861.4133330000	14.1667000000	14.8333000000	7.3333000000	7.6667000000	2210.5000000000	1146.666
28	35	1716.5247395833	818.5507812500	897.9766670000	15.0000000000	15.0000000000	5.5000000000	7.1667000000	2348.6667000000	1027.833
29	37	1800.5265625000	935.0609375000	865.4650000000	15.0000000000	15.0000000000	8.5000000000	6.6000000000	2079.4000000000	960.700
30	36	1917.6067708333	1030.6692708333	886.9383330000	15.0000000000	14.6667000000	8.5000000000	8.1667000000	1955.8333000000	1005.666
31	39	1887.7871093750	943.4544270833	944.3325000000	14.9167000000	15.0000000000	7.5000000000	8.2500000000	2232.0833000000	1048.000

1.1.3. Skomponowanie drużyn wraz z cechami predykcyjnymi

Z uśrednionych wierszy (zawodników) zostały skomponowane drużyny - każda po 5 zawodników. Wspomniane kompozycje nie były przypadkowe. Utworzone składy w jakich występowały gracze, uczestniczyły wcześniej podczas analizowanych historycznych rozgrywek (poszczególnych meczy). Dzięki takiej kompozycji uzyskano zbiór pożądaných cech obu stron potyczki wraz jej końcowym wynikiem. Dzięki temu zabiegowi, wspomniane cechy drużyn, były tożsame z cechami indywidualnego gracza, co jest kluczowe w kontekście kamieni milowych. Innymi słowy otrzymano listę rozegranych meczy (**Rys. 3**) z uśrednionymi charakterystykami drużyn (atrybuty warunkowe) oraz atrybutem decyzyjnym jakim była informacja o tym kto wygrał mecz (jaka drużyna - a tym samym jacy zawodnicy). W konsekwencji (o czym szczegółowo raportujemy w dalszej części dokumentu) uzyskano model nadzorowanego uczenia maszynowego umiejący (z ponad losowym prawdopodobieństwem) przewidywać, kto wygra przyszłą potyczkę z dodatkową informacją, jakie cechy zawodników mają największy wpływ na wygraną (**ważne w kontekście spełnienia założeń kamieni milowych tego etapu**).



Rysunek 3: Fragment widoku zbioru danych – zestawienie cech obu drużyn z informacją kto wygrał potyczkę (ang. winner).

ivs4_r_t1	ivs3_won_r_t2	ivs3_won_r_t1	ivs3_r_t2	ivs3_r_t1	ivs2_won_r_t2	ivs2_won_r_t1	ivs2_r_t2	ivs2_r_t1	ivs1_won_r_t2	ivs1_won_r_t1	ivs1_r_t2	ivs1_r_t1	winner
winning	winning	winning	winning	winning	winning	winning	winning	winning	winning	winning	winning	winning	winning
Decimal	Decimal	Decimal	Decimal	Decimal	Decimal	Decimal	Decimal	Decimal	Decimal	Decimal	Decimal	Decimal	Text
0.023107449902593	0	0	0.02278453372398	0.0215564569619	0.008414114751007	0.003412035586113	0.035238890824737	0.021247151674231	0.06708241427041	0.011321466829148	0.013643195406617	0.010129656607855	12
0.023107449902593	0	0	0.02278453372398	0.0215564569619	0.008414114751007	0.003412035586113	0.035238890824737	0.021247151674231	0.06708241427041	0.011321466829148	0.013643195406617	0.010129656607855	11
0.034744255726515	0.00090568876264	0.001276300450977	0.02865184181075	0.039012440327342	0.000226977291132	0.00741922934774	0.032669618067761	0.024054024802917	0.00732981858531	0.015158120188371	0.014129779478785	0.020502565501287	11
0.034744255726515	0.00090568876264	0.001276300450977	0.02865184181075	0.039012440327342	0.000226977291132	0.00741922934774	0.032669618067761	0.024054024802917	0.00732981858531	0.015158120188371	0.014129779478785	0.020502565501287	11
0.0301270201187	0.001433779743739	0.001223643484129	0.031356897378999	0.020840178089073	0.004181339164327	0.006304211230233	0.016205022142148	0.028690462861503	0.018112712479168	0.006986392472635	0.018354186740531	0.011586374040347	12
0.0301270201187	0.001433779743739	0.001223643484129	0.031356897378999	0.020840178089073	0.004181339164327	0.006304211230233	0.016205022142148	0.028690462861503	0.018112712479168	0.006986392472635	0.018354186740531	0.011586374040347	12
0.03485678545479	0.000837848498894	0.000745918798534	0.02739164591383	0.036425825648194	0.006012509192036	0.00313215588435	0.025931411040765	0.019068295206316	0.018000922806337	0.00940511562301	0.014525956010227	0.017078959770626	11
0.03485678545479	0.000837848498894	0.000745918798534	0.02739164591383	0.036425825648194	0.006012509192036	0.00313215588435	0.025931411040765	0.019068295206316	0.018000922806337	0.00940511562301	0.014525956010227	0.017078959770626	12
0.021030411584746	0.002429344931998	0	0.031013899139857	0.027147684378531	0.00542618484011	0.00494053040752	0.01862432996668	0.025534025043559	0.015992863555328	0.008049328387127	0.019759319938997	0.01472481079133	11
0.021030411584746	0.002429344931998	0	0.031013899139857	0.027147684378531	0.00542618484011	0.00494053040752	0.01862432996668	0.025534025043559	0.015992863555328	0.008049328387127	0.019759319938997	0.01472481079133	12
0.028199468597756	0.000478878116045	0.000377953232067	0.023335403384087	0.029648541289501	0.00920290048551	0.009049712188614	0.02675903731718	0.022655650589796	0.00680901842647	0.007412796740531	0.009717522201944	0.010750879686148	12
0.028199468597756	0.000478878116045	0.000377953232067	0.023335403384087	0.029648541289501	0.00920290048551	0.009049712188614	0.02675903731718	0.022655650589796	0.00680901842647	0.007412796740531	0.009717522201944	0.010750879686148	12
0.022681370091807	0.000814395709476	0.001132820902021	0.028721668294763	0.02780618212397	0.003585672370872	0.001921470342523	0.02351233991425	0.02124394319131	0.00776188473493	0.0077699757727852	0.01553052853676	0.012364243943191	11
0.022681370091807	0.000814395709476	0.001132820902021	0.028721668294763	0.02780618212397	0.003585672370872	0.001921470342523	0.02351233991425	0.02124394319131	0.00776188473493	0.0077699757727852	0.01553052853676	0.012364243943191	12
0.02457350052469	0.002389750501721	0.00091383293823	0.029251304438007	0.028304022945128	0.009483253762356	0.000064820473365	0.028431302943716	0.027995029935309	0.012191110157871	0.010727833384889	0.020444280229377	0.015293302720351	12
0.02457350052469	0.002389750501721	0.00091383293823	0.029251304438007	0.028304022945128	0.009483253762356	0.000064820473365	0.028431302943716	0.027995029935309	0.012191110157871	0.010727833384889	0.020444280229377	0.015293302720351	12
0.02466594587895	0.00680760846754	0.001728679368975	0.027920992280472	0.032866424050899	0.007397376527844	0.002689505047024	0.02947706568178	0.018074146292265	0.01148316770044	0.005859422930373	0.018538937712834	0.013815987426564	12
0.02466594587895	0.00680760846754	0.001728679368975	0.027920992280472	0.032866424050899	0.007397376527844	0.002689505047024	0.02947706568178	0.018074146292265	0.01148316770044	0.005859422930373	0.018538937712834	0.013815987426564	11
0.022807053844345	0.003026439937367	0	0.022781869863829	0.028920385610158	0.00466617167883	0.000940512579356	0.017745264998477	0.019750387961439	0.00685079054178	0.01293167176111	0.010744011010392	0.017398858923113	11
0.022807053844345	0.003026439937367	0	0.022781869863829	0.028920385610158	0.00466617167883	0.000940512579356	0.017745264998477	0.019750387961439	0.00685079054178	0.01293167176111	0.010744011010392	0.017398858923113	12
0.03353256645958	0.003267936067747	0.000698595134499	0.024801034547361	0.0260033875438	0.0063732967011	0.00349295767496	0.02406511909703	0.02367473708605	0.007576928036671	0.011255016389897	0.011333001622867	0.021035351521894	12
0.03353256645958	0.003267936067747	0.000698595134499	0.024801034547361	0.0260033875438	0.0063732967011	0.00349295767496	0.02406511909703	0.02367473708605	0.007576928036671	0.011255016389897	0.011333001622867	0.021035351521894	12

1.2. Wybór najskuteczniejszego algorytmu uczenia maszynowego

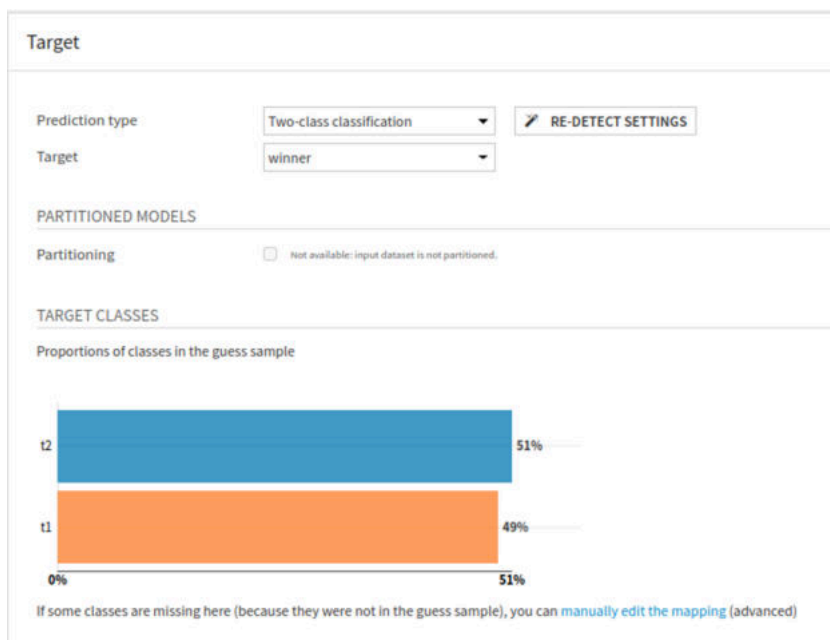
Podczas tego etapu przeprowadzono szereg badań porównawczych, zasilając zbiorem uczącym a następnie analizując wyniki wielu różnych algorytmów (Rys. 4)

Rysunek 4: Lista badanych algorytmów uczenia maszynowego – zawiera wyniki w postaci precyzji

<input type="checkbox"/>	SESSION 2		
<input type="checkbox"/>	Random forest (NO RESCALING)	0.687	☆
<input type="checkbox"/>	Gradient Boosted Trees (NO RESCALING)	0.702	☆
<input type="checkbox"/>	Logistic Regression (NO RESCALING)	🏆 0.723	☆
<input type="checkbox"/>	XGBoost (NO RESCALING)	0.680	☆
<input type="checkbox"/>	Decision Tree (NO RESCALING)	0.661	☆
<input type="checkbox"/>	K Nearest Neighbors (k=5) (NO RESCALING)	0.532	☆
<input type="checkbox"/>	Extra trees (NO RESCALING)	0.665	☆
<input type="checkbox"/>	Artificial Neural Network (NO RESCALING)	0.545	☆
<input type="checkbox"/>	LASSO-LARS (NO RESCALING)	0.714	☆
<input type="checkbox"/>	SGD (NO RESCALING)	0.549	☆
<input type="checkbox"/>	SVM (NO RESCALING)	0.508	☆

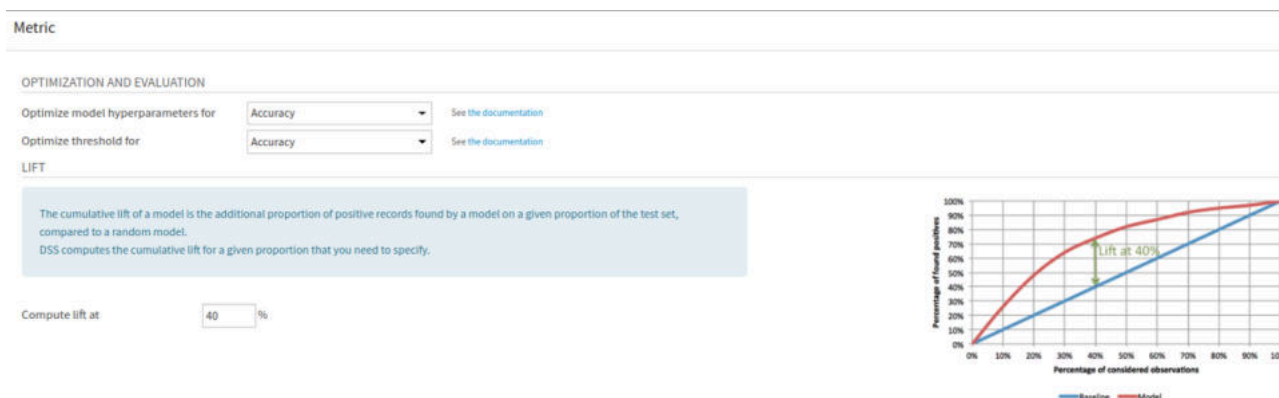
Celem każdego z algorytmów było wytypowanie zwycięzcy (**Rys. 5** - „Target” - „winner”) z możliwie największym prawdopodobieństwem.

Rysunek 5: Widok celu (kto zwycięży mecz) algorytmów uczenia maszynowego.



Ponieważ celem predykcji była tylko jedna cecha, której wartość można przedstawić w sposób binarny (wygrana / przegrana), do oceny jakości klasyfikacji można było wybierać spośród kilku opcji np.: F1 Score, Accuracy, Precision, Recall, AUC itp. Wybór padł na metrykę jaką jest precyzja (ang. accuracy, **Rys. 6**).

Rysunek 6: Wybrana metryka – precyzja – (ang. Accuracy) do oceny jakości klasyfikacji.



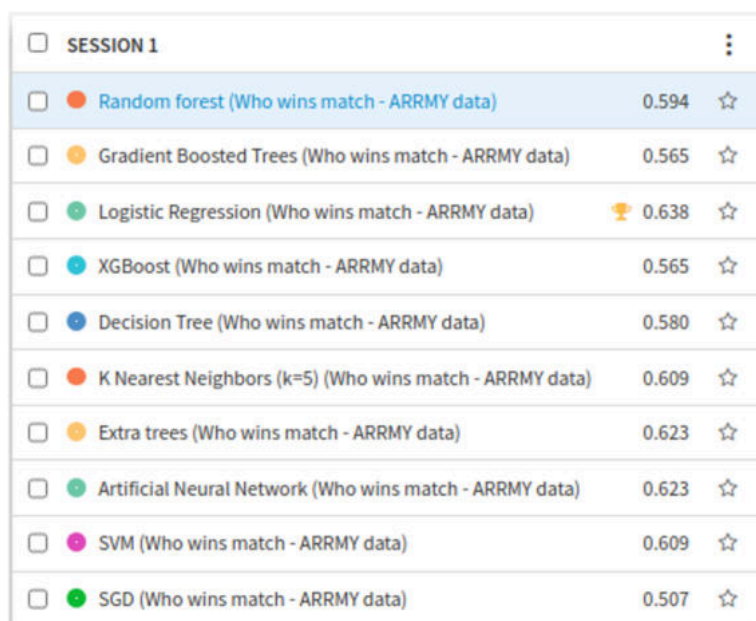
Skorzystano z precyzji ponieważ badana cecha rozkładała się w proporcji wysoce zbliżonej do 50:50% (**Rys. 5**) co w takim wypadku jest zjawiskiem pożądanym. Samo „accuracy” jest również jednym z



najbardziej intuicyjnych wskaźników dla wspomnianego rozkładu, gdyż wyraża po prostu procentowy udział trafnych predykcji.

Jak wynika z (Rys. 4) spośród 11 przebadanych modeli, wygraną drużynę najskuteczniej przewidywał model **Regresji Logistycznej** (ang. Logistic Regression) z precyzją na poziomie **72,3%**. W tym miejscu należy zaznaczyć, że tak wysoki wynik, udało się osiągnąć dzięki celowemu zwiększeniu badanej próby (ilości przebadanych meczy: **11429**) poprzez pobranie i sparsowanie dodatkowych dem z portalu faceit.com - **dane uczące (80%) i testowe (20%) pochodziły z tego samego źródła**. Zdecydowano się na takie podejście ponieważ ilość dostępnych rozgrywek wygenerowanych w projekcie ARMY na dzień badań (należy pamiętać, że ilość danych we wspomnianym projekcie sukcesywnie rośnie z biegiem czasu i badania będą cyklicznie ponawiane) wynosiła **334**, co dało precyzję przewidywanej cechy (wygrana) na poziomie **63,8%** (Rys. 7).

Rysunek 7: Lista badanych algorytmów uczenia maszynowego – zawiera wyniki w postaci precyzji (ang. Accuracy).




SESSION 1		
<input type="checkbox"/>	Random forest (Who wins match - ARMY data)	0.594 ☆
<input type="checkbox"/>	Gradient Boosted Trees (Who wins match - ARMY data)	0.565 ☆
<input type="checkbox"/>	Logistic Regression (Who wins match - ARMY data)	🏆 0.638 ☆
<input type="checkbox"/>	XGBoost (Who wins match - ARMY data)	0.565 ☆
<input type="checkbox"/>	Decision Tree (Who wins match - ARMY data)	0.580 ☆
<input type="checkbox"/>	K Nearest Neighbors (k=5) (Who wins match - ARMY data)	0.609 ☆
<input type="checkbox"/>	Extra trees (Who wins match - ARMY data)	0.623 ☆
<input type="checkbox"/>	Artificial Neural Network (Who wins match - ARMY data)	0.623 ☆
<input type="checkbox"/>	SVM (Who wins match - ARMY data)	0.609 ☆
<input type="checkbox"/>	SGD (Who wins match - ARMY data)	0.507 ☆

Nie jest to zły wynik, jednak na bazie przeprowadzonych własnych doświadczeń (Rys. 8), wiedzieliśmy, że większa ilość danych da nam lepsze rezultaty.



Tabela 8: Krzywa uczenia – wpływ ilość danych uczących na przewidywany stopień precyzji predykcji dwóch przykładowych algorytmów uczenia maszynowego.



Jak pokazują przeprowadzone badania, było to słuszne założenie. Mając wytrenowany model z precyzją ponad 72% można było pójść o krok dalej i przetestować go na danych z projektu ARRM. Innymi słowy do uczenia modelu wykorzystano dane (100%) o przybliżonej wartości (dane z dem faceit.com), natomiast do testu weryfikacyjnego użyto danych (100%) z ARRM. Dzięki temu, pomimo niewielkiej próby docelowej, udało się wytypować i stworzyć model, który przewidywał wygraną na poziomie **66,6%** (Rys. 9). Tym razem najlepiej spisał się algorytm **Sztucznych Sieci Neuronowych** (ang. Artificial Neural Network). Według naszej oceny, uzyskany wynik spełnia kryteria kamieni milowych projektu.

Rysunek 9: Lista badanych algorytmów uczenia maszynowego – zawiera wyniki w postaci precyzji (ang. Accuracy).

<input type="checkbox"/>	SESSION 6		⋮
<input type="checkbox"/>	● Random forest	0.618	☆
<input type="checkbox"/>	● Logistic Regression	0.640	☆
<input type="checkbox"/>	● Artificial Neural Network	🏆 0.666	☆



Należy pamiętać, że z upływem czasu a więc przyrostu docelowej badanej próby, precyzja predykcji będzie się poprawiać, co udowadnia wspomniany powyżej rezultat przebadanej próby z portalu faceit.com.

2. Wykrycie artefaktów, które warto byłoby usunąć przed przesłaniem danych do algorytmu uczenia maszynowego w celu optymalizacji procesu

W poprzednim etapie II, zespół stworzył parser dem w którym opracowane zostały funkcje wydobywające około 330 cech każdego zawodnika. Podczas prac nad etapem III dopisaliśmy dodatkowe funkcje których wynikiem jest lista 24 nowych cech:

time_to_hurt, time_to_hurt_t, time_to_hurt_ct, hurt_amount, hurt_amount_t, hurt_amount_ct, time_to_kill, time_to_kill_t, time_to_kill_ct, flashbang_thrown, flashbang_thrown_t, flashbang_thrown_ct, molotov_thrown, molotov_thrown_t, molotov_thrown_ct, hegrenade_thrown, hegrenade_thrown_t, hegrenade_thrown_ct, smokegrenade_thrown, smokegrenade_thrown_t, smokegrenade_thrown_ct, penetrated_kills, penetrated_kills_t, penetrated_kills_ct

Zauważono, że usunięcie cech wyszczególniających stronę po jakiej grał zawodnik (ct – antyterrorysty, t – terrorysty) znacznie uprościło model oraz **poprawiło wyniki (około 3,5%)** w stosunku do tych, które przedstawiliśmy w **punkcie 1** niniejszego raportu.

3. Stworzenie funkcji zajmujących się skalowaniem cech oraz transformacji do znormalizowanego poziomu w celu umożliwienia ich badania za pomocą różnych algorytmów uczenia maszynowego

W związku z tym, że niektóre algorytmy uczenia maszynowego są mniej lub bardziej wrażliwe na proces skalowania danych, postanowiliśmy podejść do tematu kompleksowo. W tym wypadku przeprowadzono badania nad dwoma metodami skalowania (ang. Rescaling) oraz bez skalowania wartości, dla 10 różnych algorytmów. Poniższe zestawienie wyników wskazuje, że **największą precyzję typowania wygranej wykazał algorytm Regresji Logistycznej bez skalowania danych:**

3.1. MIN-MAX RESCALING (wynik 71,1%)

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)}$$



Rysunek 10: Wynik badanych algorytmów uczenia maszynowego - min-max rescaling.

SESSION 2		
<input type="checkbox"/>	Random forest (MIN-MAX RESCALING)	0.677 ☆
<input type="checkbox"/>	Gradient Boosted Trees (MIN-MAX RESCALING)	🏆 0.711 ☆
<input type="checkbox"/>	Logistic Regression (MIN-MAX RESCALING)	0.702 ☆
<input type="checkbox"/>	XGBoost (MIN-MAX RESCALING)	0.701 ☆
<input type="checkbox"/>	Decision Tree (MIN-MAX RESCALING)	0.683 ☆
<input type="checkbox"/>	K Nearest Neighbors (k=5) (MIN-MAX RESCALING)	0.580 ☆
<input type="checkbox"/>	Extra trees (MIN-MAX RESCALING)	0.669 ☆
<input type="checkbox"/>	Artificial Neural Network (MIN-MAX RESCALING)	0.655 ☆
<input type="checkbox"/>	SGD (MIN-MAX RESCALING)	0.699 ☆
<input type="checkbox"/>	SVM (MIN-MAX RESCALING)	0.676 ☆

3.2. AVG-STD RESCALING (wynik 71,9%)

$$x' = \frac{x - \text{average}(x)}{\text{max}(x) - \text{min}(x)}$$

Rysunek 11: Wynik badanych algorytmów uczenia maszynowego – avg-std rescaling.

SESSION 3		
<input type="checkbox"/>	Random forest (AVG-STD RESCALING)	0.687 ☆
<input type="checkbox"/>	Gradient Boosted Trees (AVG-STD RESCALING)	0.703 ☆
<input type="checkbox"/>	Logistic Regression (AVG-STD RESCALING)	0.718 ☆
<input type="checkbox"/>	XGBoost (AVG-STD RESCALING)	0.680 ☆
<input type="checkbox"/>	Decision Tree (AVG-STD RESCALING)	0.661 ☆
<input type="checkbox"/>	K Nearest Neighbors (k=5) (AVG-STD RESCALING)	0.580 ☆
<input type="checkbox"/>	Extra trees (AVG-STD RESCALING)	0.665 ☆
<input type="checkbox"/>	Artificial Neural Network (AVG-STD RESCALING)	0.668 ☆
<input type="checkbox"/>	SVM (AVG-STD RESCALING)	0.698 ☆
<input type="checkbox"/>	SGD (AVG-STD RESCALING)	0.718 ☆
<input type="checkbox"/>	LASSO-LARS (AVG-STD RESCALING)	🏆 0.719 ☆



3.3 Brak skalowania – NO – RESCALING (wynik 72,3%)

Rysunek 12: Wynik badanych algorytmów uczenia maszynowego – no rescaling.

SESSION 2		
<input type="checkbox"/>	Random forest (NO RESCALING)	0.687 ☆
<input type="checkbox"/>	Gradient Boosted Trees (NO RESCALING)	0.702 ☆
<input type="checkbox"/>	Logistic Regression (NO RESCALING)	🏆 0.723 ☆
<input type="checkbox"/>	XGBoost (NO RESCALING)	0.680 ☆
<input type="checkbox"/>	Decision Tree (NO RESCALING)	0.661 ☆
<input type="checkbox"/>	K Nearest Neighbors (k=5) (NO RESCALING)	0.532 ☆
<input type="checkbox"/>	Extra trees (NO RESCALING)	0.665 ☆
<input type="checkbox"/>	Artificial Neural Network (NO RESCALING)	0.545 ☆
<input type="checkbox"/>	LASSO-LARS (NO RESCALING)	0.714 ☆
<input type="checkbox"/>	SGD (NO RESCALING)	0.549 ☆
<input type="checkbox"/>	SVM (NO RESCALING)	0.508 ☆

4. Wyłonienie modelu klasyfikującego uczenia maszynowego, który na podstawie czynników prognostycznych wskaże etykietę rekrutacyjną (czy dany gracz może przejść do następnego etapu rekrutacji) oraz szacowany współczynnik wygralności

Z racji prac wykonanych i opisanych w **punkcie 1**, modelem opartym o algorytmy uczenia maszynowego, który najlepiej ocenia graczy w kontekście największej sprawczości przybliżenia drużyny do wygranej, okazał się:


- **72,3%** trafnych predykcji - algorytm **Regresji Logistycznej** dla danych uczących oraz testowych z portalu faceit.com
- **66,6%** trafnych predykcji - algorytm **Sztucznych Sieci Neuronowych** dla danych uczących z faceit.com oraz danych testowych z projektu ARMY.

Oczywiście w miarę upływu czasu i wzrostu liczby rozgrywek w projekcie ARMY planowane jest cykliczne powtarzanie badania, oczekując jeszcze lepszych wyników precyzji, poprzez różne kombinacje danych uczących i testowych.



Dzięki wielu wytrenowanym modelom mogliśmy ostatecznie zbadać jakie charakterystyki danego gracza najistotniej wpływają na wygraną. Ilość cech to **240 / 2** – czyli po **120** dla każdej ze stron (ilość uzyskana po redukcji opisanej w **punkcie 2.**) Grupa algorytmów, które bardzo dobrze obrazują wpływ danej cechy na wynik prognostyczny to algorytmy „drzewiaste”. Poniżej (**Rys. 13**) przedstawiamy wynik ważności cech uzyskany za pomocą **Gradient Boosted Trees**:

Rysunek 13: Widok ważności cechy w kontekście predykcji wygranej – wszystkie cechy.



Powyższe zastawienie cech dotyczy sytuacji w której algorytm przewiduje wygraną dwóch drużyn - stąd widoczne przyrostki **t1** (ang. team 1) i **t2** (ang. team 2). Jak wspomniano wcześniej, każda drużyna to kompozyt 5 zawodników. Wszystkie wartości cech są generowane na podstawie wielu historycznych rozgrywek (statystyki z wielu meczy). Zaobserwowano, że najistotniejsze cechy decyzyjne to:


- **rounds_won** – średnio wygrywanych rund na mecz, przez graczy tworzących drużynę
- **rounds** – średnio rozegranych rund na mecz, przez graczy tworzących drużynę
- **esea_rws** - współczynnik ESEA RWS (ang. esea round win share, <https://support.esea.net/hc/en-us/articles/360008740634-What-is-RWS->)
- **KDR** – średni stosunek ilości zabójstw do poniesionych śmierci (ang. kills / deaths)
- **hltv_kast** – średnia ilość rund, w których gracz zabił, miał asystę, przeżył lub został pomszczony w ciągu 3 sekund od swojej śmierci



- **damage_received** – średnia ilość otrzymywanych obrażeń
- **kills_not_seeing** – średnia ilość zabójstw graczy, którzy nie widzieli zabójcy
- **damage** – średnia ilość obrażeń zadawanych przez gracza

Na **Rys. 13** obserwujemy ponad przeciętny wpływ cech zawierających informacje o wygranych oraz rozegranych rundach. Z tego powodu celowo postanowiliśmy usunąć je z dalszych analiz aby pozbyć się wartości odstających. Wynikiem wspomnianej modyfikacji jest poniższe zestawienie ważności cech (**Rys. 14**):

Rysunek 14: Widok ważności cechy w kontekście predykcji wygranej – z pominięciem cech z przedrostkiem „rounds”



- **esea_rws** - współczynnik ESEA RWS (ang. esea round win share, <https://support.esea.net/hc/en-us/articles/360008740634-What-is-RWS->)
- **KDR** – średni stosunek ilości zabójstw do poniesionych śmierci (ang. kills / deaths)
- **hlvtv_kast** – średnia ilość rund, w których gracz zabił, miał asystę, przeżył lub został pomszczony w ciągu 3 sekund od swojej śmierci
- **deaths** – średnia ilość zadanych śmierci przez zawodników
- **kills** – średnia ilość zabójstw
- **damage_received** – średnia ilość otrzymywanych obrażeń
- **damage** – średnia ilość obrażeń zadanych przez graczy

- **OKDR** – stosunek otwierających zabójstw do otwierających śmierci (ang. opening kills / opening deaths)
- **kills_advantage** – średnia ilość zabójstw kiedy gracz posiada przewagę broni
- **total_time_to_death_sec** – średnia ilość sekund do śmierci
- **kills_not_seeing** - średnia ilość zabójstw graczy, którzy nie widzieli zabójcy
- **3K** – średnia ilość rund, w których gracz zdobył 3 zabójstwa

W powyższym zestawieniu oraz na **Rys. 15**, na zielono zostały zaznaczone cechy które najmocniej korelowały z oceną ekspertów dziedzinowych (trenerzy). Ma to niebagatelne znaczenie, ponieważ ukazuje zbieżność między typami „sztucznej inteligencji” a wieloletnim doświadczeniem umysłu ludzkiego. Jest to dla zespołu bardzo pozytywne zjawisko, które utwierdza w przekonaniu, że **wykonane prace wnoszą dużą wartość biznesową**.

Rysunek 15: Widok korelacji cechy **avg_rating** (ocena eksperta dziedzinowego) w stosunku do przebadanych cech. Zielone obramowanie wyróżnia kilka spośród najważniejszych charakterystyk, wytypowanych przez algorytm uczenia maszynowego.

Pearson correlation			
N avg_rating			
Filter ...			
1	+0.949	avg_rating	skills
2	+0.932	avg_rating	communication
3	+0.905	avg_rating	shooting
4	+0.632	avg_rating	kills
5	+0.605	KDR	avg_rating
6	+0.588	avg_rating	damage
7	+0.586	avg_rating	kills_ct
8	+0.583	avg_rating	rounds_with_kill
9	+0.577	adr	avg_rating
10	+0.559	avg_rating	hltv_kast
11	+0.554	avg_rating	kills_not_seeing
12	+0.543	avg_rating	kills_distance
13	+0.541	avg_rating	rounds_with_kill_ct
14	+0.527	avg_rating	dmg_hitgroup_chest
15	+0.524	avg_rating	damage_ct
16	+0.523	avg_rating	kills_not_seeing_ct
17	+0.520	avg_rating	kills_t
18	+0.519	avg_rating	medium_distance_kills
19	+0.517	2K	avg_rating
20	+0.514	avg_rating	kills_distance_ct
21	+0.507	avg_rating	hltv_kast_ct
22	+0.498	avg_rating	damage_t



Biorąc pod uwagę wszystkie przedstawione w raporcie czynniki, czyli wyniki algorytmów uczenia maszynowego (predykcje wygranej znacznie powyżej wartości losowych) skorelowane z oceną ekspertów, stworzyliśmy **wzór oceniający indywidualnego zawodnika (Rys. 16)**.

Player Power (PP) - jako etykieta rekrutacyjna

przedrostek **nor** – oznacza, że dana cecha jest skalowana wzorem z **punktu 3.1**

Rysunek 16: Wzór na wartość etykiety rekrutacyjnej - **Player Power**

$$PP = \frac{norKDR * 4 + norHltvKast * 4 + norDamage * 2 + norKillsNotSeeing * 1}{4 + 4 + 2 + 1}$$

Wartość brzegowa (próg od którego zawodnik przechodzi do dalszego etapu) jest dynamiczny - zależy od kontekstu rozgrywek. Wpływ na ustaloną wartość ma między innymi:

- ogólny poziom umiejętności wszystkich ocenianych zawodników
- ilości zawodników
- poziom etapu w jakim rozgrywane są mecze

Aktualnie wspomniany próg ma wartość **6 PP**. Innymi słowy do dalszego etapu rozgrywek, przejdzie każdy zawodnik (**Rys. 17**) którego wartość etykiety rekrutacyjnej jest większa lub równa 6 PP.

Rysunek 17: Fragment widoku bazy danych – ewaluacja graczy na podstawie etykiety rekrutacyjnej

Player_ID	PLAYER_POWER	KDR	nor_KDR	hltv_kast	nor_hltv_kast	damage	nor_damage	kills_not_seeing	nor_kills_not_seeing
633	10.009267809543439348	1.743...	0.9687...	22.5000...	0.7950819...	3757....	1.0000000...	19.0000000...	0.95384615384615
127	9.525703799659737741	1.739...	0.9656...	22.7500...	0.8155737...	2984....	0.7004456...	19.7500000...	1.00000000000000
565	9.425318409425885596	1.526...	0.8155...	25.0000...	1.0000000...	3213....	0.7891881...	13.0000000...	0.58461538461538
563	9.305896373588310668	1.750...	0.9732...	24.0000...	0.9180327...	2668....	0.5779887...	13.0000000...	0.58461538461538
655	8.714238807073042874	1.764...	0.9836...	21.0000...	0.6721311...	3080....	0.7378415...	13.5000000...	0.61538461538462
355	8.654749531583359720	1.544...	0.8284...	22.4000...	0.7868852...	3038....	0.7214105...	15.7000000...	0.75076923076923
615	8.382533859730545017	1.666...	0.9145...	22.3333...	0.7814180...	2432....	0.4865336...	13.6667000...	0.62564307692308
623	8.32912777273311388	1.676...	0.9214...	20.5000...	0.6311475...	2878....	0.6593683...	16.5000000...	0.80000000000000
179	8.269026406790553906	1.604...	0.8708...	21.5000...	0.7131147...	2567....	0.5389653...	17.4000000...	0.85538461538462
263	8.260638679596299283	1.481...	0.7842...	22.3750...	0.7848360...	2838....	0.6440612...	14.8125000...	0.69615384615385
299	8.203683998208499803	1.787...	0.9999...	19.0000...	0.5081967...	2786....	0.6239100...	18.5000000...	0.92307692307692
567	8.140716969146907710	1.500...	0.7970...	22.0000...	0.7540983...	2841....	0.6450300...	14.0000000...	0.64615384615385
137	8.019165978396942261	1.575...	0.8504...	22.0000...	0.7540983...	2408....	0.4774268...	14.0000000...	0.64615384615385
622	8.015158057982299795	1.395...	0.7230...	22.0000...	0.7540983...	2941....	0.6840728...	15.5000000...	0.73846153846154
153	7.933085935150345713	1.446...	0.7590...	23.2500...	0.8565573...	2339....	0.4506878...	12.7500000...	0.56923076923077
293	7.688919831386339073	1.352...	0.6930...	21.6250...	0.7233606...	2863....	0.6538945...	15.1250000...	0.71538461538462
180	7.672630024502173083	1.500...	0.7970...	20.5000...	0.6311475...	2951....	0.6876574...	13.0000000...	0.58461538461538

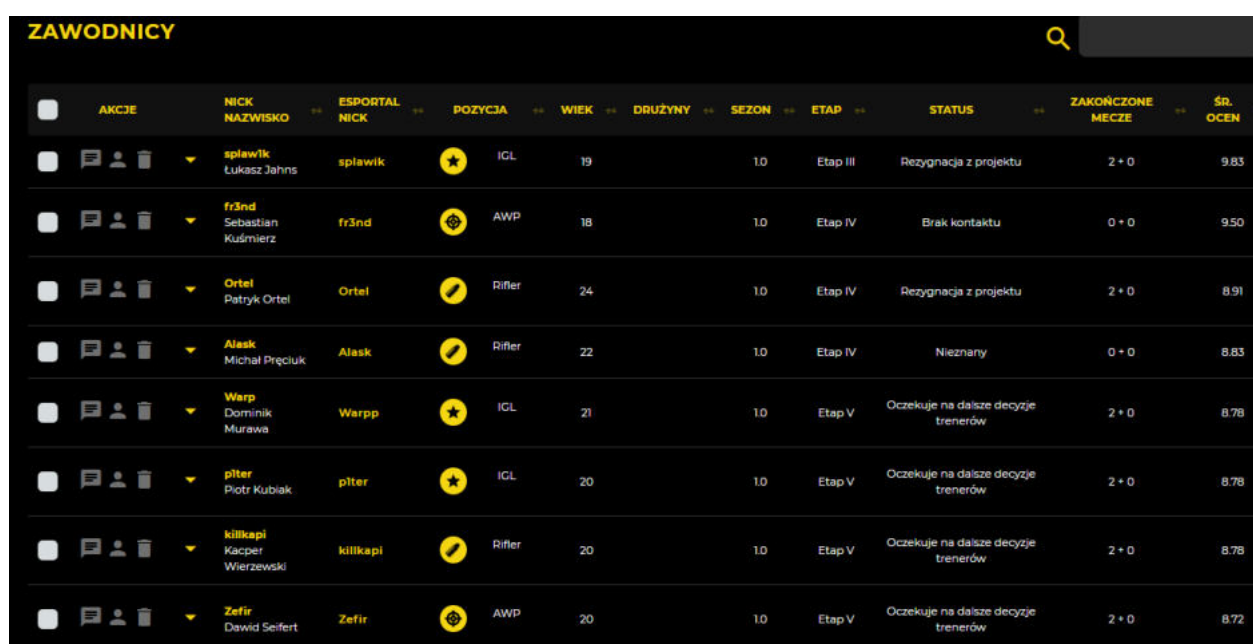
Pomimo bardzo dobrych wyników „sztucznej inteligencji” - w projekcie ARRM, ostateczną decyzję o tym kto przejdzie dalej, podejmuje trener wspólnie z pomocnikami. Uczenie maszynowe ma być pomocne



w tej decyzji i jak obserwujemy, wyniki z upływem czasu i przyrostem danych są coraz bardziej obiecujące.

Prace trenerów opierały się już na panelu administracyjnym, który ułatwiał procedurę oceny i zarządzania wiedzą oraz samymi rozgrywkami. Przeprowadzono III etap rekrutacji, który na podstawie przeszło 90 meczów wytypował 153 osoby o najlepszych umiejętnościach. Dla osób, które nie otrzymały awansu sporządzone zostały analizy ich rozgrywek wskazujące ich błędy i obszary do udoskonalenia. Dużym atutem jest archiwizacja meczów w systemie, które pozwala powrócić do danej rozgrywki i potwierdzić niektóre oceny. Dzięki stworzonej bazie i łatwemu jej sortowaniu trenerzy mają do dyspozycji pełną informacje o uczestnikach:

Rysunek 18: Fragment widoku bazy graczy zawierający podstawowe informacje i ocenę trenerską



AKCJE	NICK NAZWISKO	ESPORTAL NICK	POZYCJA	WIEK	DRUŻYNY	SEZON	ETAP	STATUS	ZAKOŃCZONE MECZE	ŚR. OCEN
	splawik Lukasz Jahns	splawik	IGL	19		1.0	Etap III	Rezygnacja z projektu	2 + 0	9.83
	fr3nd Sebastian Kuźmierz	fr3nd	AWP	18		1.0	Etap IV	Brak kontaktu	0 + 0	9.50
	Ortel Piotr Ortel	Ortel	Rifler	24		1.0	Etap IV	Rezygnacja z projektu	2 + 0	8.91
	Alask Michał Pręciuk	Alask	Rifler	22		1.0	Etap IV	Nieznany	0 + 0	8.83
	Warp Dominik Murawa	Warpp	IGL	21		1.0	Etap V	Oczekuje na dalsze decyzje trenerów	2 + 0	8.78
	płter Piotr Kubiak	płter	IGL	20		1.0	Etap V	Oczekuje na dalsze decyzje trenerów	2 + 0	8.78
	killkapi Kacper Wierzewski	killkapi	Rifler	20		1.0	Etap V	Oczekuje na dalsze decyzje trenerów	2 + 0	8.78
	Zefir Dawid Seifert	Zefir	AWP	20		1.0	Etap V	Oczekuje na dalsze decyzje trenerów	2 + 0	8.72

Przyznane oceny są wypadkową ocen trenerów obserwujących dany mecz i danego zawodnika. Po każdym ze spotkań gracz otrzymywał telefoniczną ekspertyzę, wyjaśniającą skąd dana ocena i awans/odpadnięcie z dalszej fazy projektu. Sama ocena zostawała wprowadzona do systemu, co ilustruje poniższy rysunek:



Rysunek 19: Fragment widoku bazy graczy zawierający widok trenera służący do oceny zawodnika

OCENY ZAWODNIKÓW I NOTATKI										
21_04_2020_KUBIK_TEAMA										
	MISIAJ Michał Gajdos MISIAJ Etap IV		<input type="checkbox"/>	5.33	KOMUNIKACJA ★★★★★ ★★★★★	STRZELANIE ★★★★★ ★★★★★	UMIEJĘTNOŚCI DRUŻYNOWE ★★★★★ ★★★★★			
	broda Mateusz Brodowski brodac Etap IV		<input type="checkbox"/>	8.00	KOMUNIKACJA ★★★★★ ★★★★★	STRZELANIE ★★★★★ ★★★★★	UMIEJĘTNOŚCI DRUŻYNOWE ★★★★★ ★★★★★			
	Komoda22cm Michał Matczak komoda Etap III		<input type="checkbox"/>	7.00	KOMUNIKACJA ★★★★★ ★★★★★	STRZELANIE ★★★★★ ★★★★★	UMIEJĘTNOŚCI DRUŻYNOWE ★★★★★ ★★★★★			
	Termek Damian Barć Termek Etap III		<input type="checkbox"/>	6.67	KOMUNIKACJA ★★★★★ ★★★★★	STRZELANIE ★★★★★ ★★★★★	UMIEJĘTNOŚCI DRUŻYNOWE ★★★★★ ★★★★★			
	Fraz Olivier Grygiel Fraziu Etap V		<input type="checkbox"/>	7.00	KOMUNIKACJA ★★★★★ ★★★★★	STRZELANIE ★★★★★ ★★★★★	UMIEJĘTNOŚCI DRUŻYNOWE ★★★★★ ★★★★★			

Zostały także zarchiwizowane wszystkie dotychczasowe rozgrywki wraz z dostępnymi do dem i statystyk danego meczu (Rys. 20):

Rysunek 20: Fragment widoku bazy graczy zawierający statystyki przykładowego spotkania

WSZYSTKIE MIRAGE OVERPASS										
12_05_2020_Klusek_TeamA										
	KILLS (HS)	ASSISTS	DEATHS	K-D DIFF	KDR	HS%	OK	OD	OKDR	CLUTCHES
	35 (20)	12	46	-11	0.76	57%	11	13	0.85	1
	36 (10)	10	35	+1	1.03	28%	12	8	1.50	1
	34 (24)	10	39	-5	0.87	71%	6	10	0.60	1
	59 (28)	6	39	+20	1.51	47%	14	13	1.08	1
	58 (21)	7	39	+19	1.49	36%	14	13	1.08	2
12_05_2020_Klusek_TeamB										
	KILLS (HS)	ASSISTS	DEATHS	K-D DIFF	KDR	HS%	OK	OD	OKDR	CLUTCHES
	39 (15)	7	43	-4	0.91	38%	10	7	1.43	1
	45 (16)	12	45	0	1.00	36%	17	13	1.31	1
	33 (12)	8	49	-16	0.67	36%	9	12	0.75	0
	19 (4)	11	48	-29	0.40	21%	5	19	0.26	1
	58 (26)	11	41	+17	1.41	45%	16	6	2.67	2

Całość bazy danych jest dostępna do wglądu pod adresem army.pl, jednak pełne widoki dostępne tylko z rangą administratora.

Data realizacji: do 01.11.2020

podpisano: Aleksander Kaim

3.3. Porównanie systemu wyszukania drużyn AI do klasyfikatora eksperckiego.

1. Stworzenie API umożliwiającego pobieranie danych potrzebnych do zasilania modelu uczenia maszynowego

W poprzednich etapach prac stworzyliśmy parser, za pomocą którego jesteśmy w stanie analizować ponad 330 zmiennych opisujących grę każdego zawodnika. Wszystkie te dane zostały umieszczone w bazie danych (Rys. 1).

Rys 1. Fragment bazy danych zawierający informacje opisujące danego gracza w danym meczu.

name	steamid2	alive	alive_t	alive_ct	rounds_t	rounds_ct	rounds_won_t	rounds_won_ct	damage	damage_t	damage_ct	adr	damage_received
Bakasuraa	STEAM_1:0:441466373	1804.8750000000	880.0000000000	924.68	12	15	2	9	2082	691	1391	77.1111111111	2406
breaaKKK	STEAM_1:1:42651680	1787.3671875000	909.6953125000	877.67	15	12	6	10	2082	743	1339	77.1111111111	1991
mkipal	STEAM_1:1:95596428	1857.4218750000	772.8984375000	1084.52	12	15	2	9	1765	550	1215	67.8846153846	1951
MikeyJ	STEAM_1:0:30246208	1938.6875000000	1074.9921875000	863.70	15	12	6	10	1705	458	1247	63.1481481481	1912
Roche	STEAM_1:1:41774155	1992.5234375000	876.8984375000	1115.63	12	15	2	9	1812	942	870	67.1111111111	1482
blqje	STEAM_1:0:29074087	2054.2734375000	1108.8750000000	945.40	15	12	6	10	1451	351	1100	53.7407407407	1840
NTG	STEAM_1:1:51031059	1927.3828125000	1002.9531250000	924.43	15	12	6	10	2209	1589	670	83.6666666667	1978
GoLdi	STEAM_1:0:59072780	1932.2968750000	755.3359375000	1176.96	12	15	2	9	1756	565	1191	67.5384615385	1772
Sm0Ke77	STEAM_1:0:107122659	1983.5468750000	979.2968750000	1004.25	15	12	6	10	2234	657	1577	82.7407407407	1818
moska1	STEAM_1:1:153940013	1667.8984375000	747.3359375000	920.56	12	15	2	9	1859	226	1633	71.5000000000	2146
MikeyJ	STEAM_1:0:30246208	1710.2109375000	862.4375000000	847.77	15	15	4	10	2744	1166	1578	91.4666666667	2571
mkipal	STEAM_1:1:95596428	1653.4609375000	825.0312500000	828.43	15	15	5	11	3056	1070	1986	101.8666666667	2064
breaaKKK	STEAM_1:1:42651680	1717.0078125000	777.8984375000	939.11	15	15	4	10	2061	1004	1057	68.7000000000	2183
Roche	STEAM_1:1:41774155	1701.0312500000	726.6093750000	974.42	15	15	5	11	1645	253	1392	54.8333333333	2118
moska1	STEAM_1:1:153940013	1814.0859375000	865.4218750000	948.66	15	15	5	11	2409	1086	1323	80.3000000000	1768
Bakasuraa	STEAM_1:0:441466373	1683.5468750000	788.6093750000	894.94	15	15	5	11	2415	979	1436	80.5000000000	2220
GoLdi	STEAM_1:0:59072780	1470.7500000000	692.0000000000	778.75	15	15	5	11	2640	1175	1465	88.0000000000	2681
NTG	STEAM_1:1:51031059	1642.7031250000	763.2031250000	879.50	15	15	4	10	1837	908	929	61.2333333333	2499
Sm0Ke77	STEAM_1:0:107122659	1656.1562500000	762.8515625000	893.30	15	15	4	10	2063	848	1415	68.7666666667	2145
blqje	STEAM_1:0:29074087	1624.9296875000	795.8984375000	829.03	15	15	4	10	2293	879	1414	76.4333333333	2570
d9zz	STEAM_1:1:72469510	1355.1875000000	1052.5468750000	302.64	15	5	11	5	1861	1338	523	93.0500000000	995
Erno3	STEAM_1:1:48943105	1379.3281250000	1151.2578125000	228.07	15	5	11	5	1603	1100	503	80.1500000000	1144
czonrad	STEAM_1:0:102852170	1111.5000000000	875.1640625000	236.34	15	5	11	5	1816	1309	507	95.5789473684	1378
Woocashko	STEAM_1:0:36606158	1220.6250000000	159.0000000000	1061.63	5	15	0	4	1327	254	1073	69.8421052632	1894
KatkaX	STEAM_1:0:131459868	1146.0390625000	139.0000000000	1007.04	5	15	0	4	1258	125	1133	66.2105263158	1785

Aby oceniać, która drużyna ma większe szanse na wygraną w meczu utworzyliśmy punkt API, który zwraca dane uprzednio poddane transformacją tak, aby mogły one zasilić model uczenia maszynowego (Rys. 2). Punkt API przyjmuje kilka parametrów, które przyspieszają naszą pracę przy doborze danych wejściowych (Rys. 3)



Rys 2. Fragment danych zawodników przetransformowanych do postaci średnich drużyn „t1” i „t2”, czyli drużyna 1 i drużyna 2.

traded_deaths_r_12	traded_deaths_r_11	trade_kills_r_12	trade_kills_r_11	total_time_to_kill_sec_r_12	total_time_to_kill_sec_r_11	total_time_to_death_sec_r_12	total_time_to_death_sec_r_11	time_to_kill_r_12
0.087434227917341578	0.098704982373308659	0.086033062147326512	0.096640494041031950	18.328814351644911238	18.709901253416690790	29.59561705958391580	29.58837700804776448	0.179096091987203678
0.096144211817857282	0.09059793311154442	0.092252574675334415	0.094013220540603217	17.508146490932012972	18.921477252628652146	29.63351768502263134	29.359981127677942816	0.186787096195210335
0.084499396146043418	0.100420885294368335	0.091676483011773665	0.102340623481421524	17.794239176361794785	18.815317113921708195	28.97877474658889068	30.31444370056955897	0.17720446848953221
0.096144211817857282	0.09059793311154442	0.092252574675334415	0.094013220540603217	17.508146490932012972	18.921477252628652146	29.63351768502263134	29.359981127677942816	0.186787096195210335
0.095767384547479608	0.091435135812724749	0.087587589428576683	0.1034804049399681937	18.25906494273996305	18.80783434859598843	29.5050463660505484883	29.509402136993672425	0.197887602979419933
0.096331289395694952	0.092515779042089891	0.096915316119786897	0.098984521370969243	18.631374021959694232	18.412784836276198198	29.90466714111395529	30.30059814064548897	0.194156579971367566
0.093825907080989335	0.097295518162838632	0.091430016073815388	0.100878959678895271	17.729591028188116746	18.942923860692654941	29.54422822073634882	28.6665845250474708	0.182920513955188290
0.0990303727158006	0.08950417329249541	0.098258718591438831	0.095957788358874777	18.7176197638266363	18.206754945770605564	29.884142106392846473	28.897707672444490756	0.18875719899555212
0.095265331124239394	0.092648075421774343	0.093257220453061059	0.096205818727913089	17.90503830896564957	18.586720413671090505	29.188738506796653887	29.330058306918678450	0.200321163370614865
0.099520421716201457	0.088638038829793205	0.096559470140849848	0.099759418413658150	17.954378846882288672	18.465528856893242389	30.301187164314744359	29.091088556248573535	0.19424952022658884
0.09239778312451114	0.094976024330589509	0.094104750720783974	0.095587062820857422	18.618099671154978264	18.371841426984471132	29.958654137057259378	29.270682041115043118	0.192832531863131207
0.099120388019085878	0.094540906049312386	0.089307702196689175	0.100723266482205625	18.151082324035618452	18.751806682705408079	28.901532856892325001	30.016656168343100382	0.21034227544331716
0.093038855304538461	0.09304421798247845	0.09033045865489599	0.09556061862420696	18.41471969108783478	18.287396314355178426	29.400669684776683694	28.621853614900614848	0.196077818517342440
0.088621330557562880	0.099716009367738379	0.087412458048461061	0.090190825886939800	18.21896615537389288	17.746889393895378671	29.776526431831927400	28.736881499014807914	0.179077096825617826
0.085766086034304405	0.094051433551412905	0.099903368895223031	0.091816548567148393	18.57152333792689382	18.272349466231473439	29.50549105817254965	29.478314026702733951	0.18230836442749622
0.100271102505617589	0.088847043792502795	0.0911437838969054765	0.09100154245426325	17.599664154257730767	18.948677181492087191	28.79393358196848700	29.025673381454946573	0.211809802211623455

Rys 3. Parametry punktu API umożliwiają dobranie danych wejściowych.

```
[10]: params = {
    'include_groups': ['both_sides'], # meta, both_sides, army_data, ct_side, t_side
    'include_columns': [],
    'exclude_columns': [],
    'custom_expressions': [
        'AVG(reactions_time / reactions_amount) as avg_reaction_time'
    ],
    'randomize_teams': False,
    'skip_draw': True,
    'token': '****',
}
```

Po utworzeniu algorytmu oceny maszynowego zasilonego danymi pobranymi z API otrzymaliśmy model, który ocenia szanse na wygraną danej drużyny w systemie na podstawie jej dotychczasowych rozgrywek (Rys. 4).

Rys 4. Każda drużyna rozgrywająca mecze w sezonie 2 #ARRMY otrzymuje procentową predykcję szansy na wygraną wygenerowaną przez algorytm AI (kolumna „AI PRED.”)



Zespół trenerów projektu #ARRMY przydziela poziom każdemu zawodnikowi w sezonie 2. Średnia poziomu zawodników tworzy poziom drużyny. Tak więc drużyna z wyższym poziomem jest faworytem meczu wg trenerów. W turnieju finałowym 2 sezonu #ARRMY porównaliśmy predykcje trenerów, oraz AI (Rys. 5, Rys. 6) W rezultacie trenerzy przewidzieli wygranego w 68,75% meczy, natomiast AI okazało się lepsze i przewidziało wygranego w 78,12% meczy.

Rys 5. Pierwsze 2 kolejki drabinki wygranych w 2 sezonie projektu #ARRMY, wraz z predykcjami trenerów oraz AI.

AI	POZIOM	1 KOLEJKA	POZIOM	AI	POZIOM	2 KOLEJKA	POZIOM	AI			
		23.11 godz 18:00		50%	62.5%	24.11 godz 18:00		100%	100%		
		GODZ 19:10									
88.70 (88.74)	8.6	Whatever #1	2	TAK	TAK						
83.48 (83.55)	7.4	Jadlospis #16	0								
		GODZ 18:00 - STREAM 1									
90 (90.04)	7.9	Totalersi #8	2	NIE	TAK						
83.48 (83.55)	8.2	656GanG #9	1								
		GODZ 19:00									
90.43 (90.48)	8.2	EncePence #4	2	TAK	TAK	92.21	8.6	Whatever #1	2	TAK	TAK
70.43 (70.56)	7.8	Koskiadzik #13	0			88.74	7.9	Totalersi #8	1		
		GODZ 18:00									
83.48 (83.55)	8.1	Spryciarze #5	1	NIE	NIE	92.21	8.2	EncePence #4	2	TAK	TAK
42.61 (42.42)	8.0	Rzelasfo #12	2			46.75	8.0	Rzelasfo #12	1		
		GODZ 18:00									
99.57	8.7	AntyDPM #2	2	TAK	TAK	100.00	8.7	AntyDPM #2	2	TAK	TAK
46.52 (46.32)	7.8	BongoBang #15	0			75.32	7.9	AllenZ #10	0		
		GODZ 19:00									
90.00 (90.04)	8.5	PatrolWiedzma #7	1	NIE	NIE	69.26	7.9	Medycyna #14	1		
78.26 (78.35)	7.9	AllenZ #10	2			80.52	8.1	TyNoNieWiem #6	2	TAK	TAK
		GODZ 20:00 - STREAM 2									
94.35 (94.37)	8.6	POPIŚÓWKA #3	0	NIE	NIE						
52.38	7.9	Medycyna #14	2								
		GODZ 19:00									
78.70 (78.79)	8.1	TyNoNieWiem #6	2	TAK	TAK						
67.83 (67.97)	8.1	DobreChlopaki #11	1								

Rys 6. Pierwsze 2 kolejki drabinki przegranych w 2 sezonie projektu #ARRMY, wraz z predykcjami trenerów oraz AI.

AI	POZIOM	1 KOLEJKA LOSSER BRACKET	POZIOM	AI	POZIOM	2 KOLEJKA LOSSER BRACKET	POZIOM	AI			
		24.11 18:00		75%	75%	25.11 godz 18:00		50%	75%		
		GODZ 20:00									
60.17	8.1	DobreChlopaki #11	0	TAK	TAK	52.38	8.0	Rzelasfo #12	0		
88.74	8.6	POPIŚÓWKA #3	2			88.31	8.6	POPIŚÓWKA #3	2	TAK	TAK
		GODZ 18:00									
77.06	8.5	PatrolWiedzma #7	2	TAK	TAK	88.31	8.0	Totalersi #8	0		
44.16	7.8	BongoBang #15	0			88.31	8.5	PatrolWiedzma #7	2	TAK	TAK
		GODZ 18:45									
46.75	8.1	Spryciarze #5	0	NIE	TAK	68.40	7.9	Medycyna #14	0	NIE	TAK
69.26	7.8	Koskiadzik #13	2			75.76	7.9	Koskiadzik #13	2		
		GODZ 18:30									
73.16 (68.18)	8.2	656GanG #9	2	TAK	NIE	61.04	7.9	AllenZ #10	2	NIE	NIE
73.16 (72.29)	7.4	Jadlospis #16	0			80.09	8.2	656GanG #9	1		

Wyniki oceny AI wskazują na realizację kamienia milowego.

Data realizacji: 30.11.2020

podpisano: Aleksander Kaim



3.4 AI wskazuje conajmniej jedną drużynę, która uzyska wysokie miejsce w turnieju.

1. Stworzenie interfejsów ułatwiających wprowadzanie dodatkowych danych.

Przez dodatkowe dane należy rozumieć:

- Cechy graczy jakie uzyskaliśmy za pomocą przeprowadzonych testów psychologicznych oraz ankiet dietetycznych
- Refleks graczy oceniony za pomocą autorskiego narzędzia analizującego szybkość reakcji badanego na pojawiające się na ekranie obiekty i powiązane z nimi zadania motoryczne.
- Statystyki graczy pozyskane z cyfrowego zapisu rozgrywek, odbywających się na własnej infrastrukturze sprzętowo programowej (należy zaznaczyć, że jest to ogromny skok rozwojowy, ponieważ wcześniej byliśmy zależni od serwisów zewnętrznych).

1.1 Interfejsy do badań psychologicznych

Jednym z zadań projektu było przeprowadzenie badań psychologicznych na grupie kontrolnej graczy (przebadano 275 osób). Do tego celu zostały stworzone formularze (Rys. 1, 2, 3 i 4), za pomocą których badana grupa była w stanie wprowadzić odpowiedzi na szczegółowe pytania dotyczące swojej osobowości. Poniżej celowo przedstawiamy tylko kilka wybranych zrzutów ekranu, ponieważ całość testów jest bardzo obszerna. Niemniej jednak do niniejszego raportu załączamy pliki zawierające całą treść testów w formie tekstowej.

Rys. 1, 2, 3 i 4 Wybrane widoki interfejsów ułatwiających przeprowadzenie badań psychologicznych.

The image displays two screenshots of a web-based psychological test interface. The left screenshot, titled 'Testy I', shows a registration form with the following fields: 'Cześć!', 'Dziękuję za udział w badaniu.', a paragraph of instructions, a red asterisk indicating a required field, 'Twój Nick *', 'Twoja odpowiedź', 'Imię *', 'Twoja odpowiedź', 'Nazwisko *', 'Twoja odpowiedź', and 'Ile masz lat? *', 'Twoja odpowiedź'. A 'Dalej' button is at the bottom. The right screenshot, also titled 'Testy I', shows the test questions. It includes a red asterisk indicating a required field, 'Część 1', instructions to read statements and choose if they are true or false, a legend for the 4-point scale (1 - NIE, 2 - raczej NIE, 3 - raczej TAK, 4 - TAK), and three questions with their respective scales. Question 1: '1. Kiedy zmagam się z przeciwnościami, jestem w stanie zachować spokój, gdyż mogę polegać na swoich umiejętnościach radzenia sobie.' Question 2: '2. Jestem przekonany, że skutecznie poradziłbym sobie z nieoczekiwanymi wydarzeniami.' Question 3: '3. Gdy mam kłopoty, to zazwyczaj jestem w stanie wymyślić sposób, jak z nich wyjść.'



Testy I

***Wymagane**

Część 2

Przeczytaj uważnie każde z poniższych twierdzeń. Oceń, jak dobrze każde z nich opisuje Ciebie. Poszczególne punkty skali oznaczają:

- 1 - zdecydowanie nieprawdziwe
- 2 - w większości przypadków nieprawdziwe
- 3 - raczej nieprawdziwe
- 4 - trochę nieprawdziwe
- 5 - trochę prawdziwe
- 6 - raczej prawdziwe
- 7 - w większości przypadków prawdziwe
- 8 - zdecydowanie prawdziwe

1. Czuję się zazwyczaj zmęczony (zmęczona). *

1 2 3 4 5 6 7 8

Zdecydowanie nieprawdziwe Zdecydowanie prawdziwe

2. W czasie dyskusji czy kłótni łatwo ustępuję. *

1 2 3 4 5 6 7 8

Zdecydowanie nieprawdziwe Zdecydowanie prawdziwe

3. Energicznie realizuję zamierzenia. *

1 2 3 4 5 6 7 8

Zdecydowanie nieprawdziwe Zdecydowanie prawdziwe

57. Wolat(a)bym raczej iść własną drogą, niż przewodzić innym *.

1 2 3 4 5

Zdecydowanie się nie zgadzam zdecydowanie się zgadzam

58. Często sprawia mi dużą satysfakcję zajmowanie się teoretycznymi rozważaniami lub abstrakcyjnymi problemami *.

1 2 3 4 5

Zdecydowanie się nie zgadzam zdecydowanie się zgadzam

59. W razie potrzeby jestem skłonny(a) manipulować innymi, aby dostać to, co chcę *.

1 2 3 4 5

Zdecydowanie się nie zgadzam zdecydowanie się zgadzam

60. Dążę do doskonałości we wszystkim co robię *.

1 2 3 4 5

Zdecydowanie się nie zgadzam zdecydowanie się zgadzam

Wstecz

1.2 Interfejsy do badań dietetycznych

Analogicznie do punktu 1.1 przedstawiamy poniżej kilka wybranych zrzutów ekranu (Rys. 5 i 6), prezentujących interfejsy pomocne w badaniu nawyków żywieniowych. W tym miejscu należy wspomnieć, że szczegółowe wyniki analiz testów - zarówno psychologicznych jak i tych dotyczących diety - zostaną przedstawione w innej części raportu. Tutaj chcieliśmy się skupić głównie na prezentacji interfejsu, jaki został przedstawiony badanym. Staraliśmy się aby forma interfejsów była jak najbardziej czytelna i intuicyjna w obsłudze.

Rys. 5 i 6 Wybrane widoki interfejsów ułatwiających przeprowadzenie badań dietetycznych.

Kwestionariusz do badania zachowań żywieniowych

Szanowni Państwo,

Poniższe badanie ma celu ocenę wpływu diety, nawodnienia i suplementacji na wyniki e-sportowców.

Prosimy odpowiedzieć na wszystkie pytania najlepiej jak Pan/Pani potrafi. Jeśli nie umie Pan/Pani odpowiedzieć, to prosimy określić w przybliżeniu. Taka odpowiedź będzie dla nas bardziej pomocna niż brak odpowiedzi. Udzielone informacje są poufne.

Kwestionariusz składa się z trzech części: części A (zwyczajne żywieniowe), części B (częstość spożycia żywności) oraz części C (styl życia i dane osobowe). Pod niektórymi pytaniami zamieszczono instrukcje pomocnicze. Wypełnienie kwestionariusza zajmie Panu/Pani około 10-15 minut. W razie jakichkolwiek pytań i wątpliwości prosimy o kontakt mailowy na adres: [adres] lub pod numerem telefonu: [numer].

Z góry dziękujemy za poświęcony czas i rzetelne odpowiedzi.

Osoba odpowiedzialna za badanie: Agnieszka Sroka

***Wymagane**

Nick: *

Test_NICK

Imię *

Test_Imię

Nazwisko *

Test_Nazwisko

CZĘŚĆ A. ZWYCZAJE ŻYWIENIOWE

Oceńmy zaprzęt o Pana/Pani zwyczajne żywieniowe w ciągu ostatniego miesiąca. W tej części prosimy o zaznaczenie jednej odpowiedzi.

Ile posiłków spożywa Pan/Pani zazwyczaj w ciągu dnia? *

Posiłek - produkty żywnościowe lub ich zestawy spożywane zwyczajowo w określonych porach dnia, np. rano, w południe, wieczorem.

1 posiłek

2 posiłki

3 posiłki

4 posiłki

5 posiłków lub więcej

Czy spożywa Pan/Pani posiłki o stałych porach dnia? *

Nie

Tak, ale tylko niektóre

Tak, wszystkie

Jak często spożywa Pan/Pani żywność (pojada) między posiłkami? *

Posiadanie (śjadanie) - okazjonalne spożywanie produktów lub zestawów produktów między posiłkami, przeważnie w niewielkich ilościach.

Nigdy

1-3 razy w miesiącu

Raz w tygodniu

Kilka razy w tygodniu

Raz dziennie

Kilka razy w ciągu dnia

1.3 Interfejs badający refleks graczy

W kontekście wstępnej weryfikacji graczy, pojawiła się potrzeba szybkiej (ominięcie wymogu rozgrywania wielu meczy) oceny zdolności motorycznych – refleksu. Dodatkowo chcieliśmy zbadać czy i jaki wpływ na refleks ma choćby niewielka aktywność fizyczna. Aby osiągnąć zamierzony efekt, opracowaliśmy narzędzie zintegrowane z serwisem, oceniające prędkość reakcji zawodników na pojawiające się na ekranie komunikaty. Użytkownik miał za zadanie jak najszybciej kliknąć przycisk myszy, w momencie gdy pojawi się przed nim plansza z zielonym tłem. Narzędzie mierzy czas (w milisekundach) jaki upłynął od pojawienia się planszy do wciśnięcia przycisku myszy. Proces ten jest powtarzany trzykrotnie, po czym badany proszony jest o wykonanie dziesięciu przysiadów. Następnie po raz kolejny dokonywany jest trzykrotny pomiar refleksu. Zdarzały się przypadki przedwczesnego kliknięcia (górze brały emocje). Aby się z tym uporać w pierwszej kolejności informowaliśmy graczy o popełnionym błędzie oraz dodatkowo usunęliśmy z bazy wyników te mocno odstające od średniej.

Wyniki badania refleksu zostały zapisane do bazy danych projektu dzięki czemu możemy dowolnie łączyć je z pozostałymi metrykami graczy.

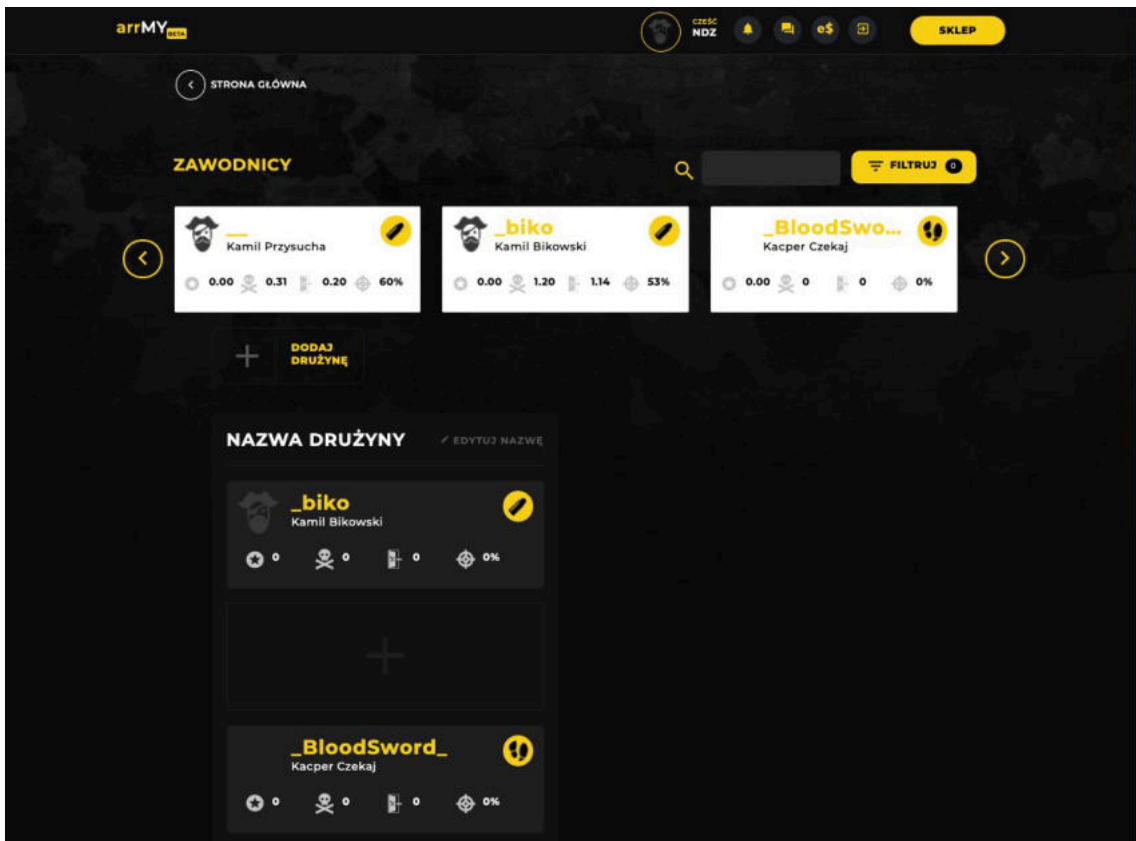
Kluczowym wnioskiem płynącym z przeprowadzonego badania jest fakt, że aktywność fizyczna (wykonywana bezpośrednio przed badaniem) miała wpływ na polepszenie wyników testu. Można to zauważyć po uśrednionych czasach reakcji przed i po wykonanych ćwiczeniach fizycznych. Poniższa tabela prezentuje średnie czasy zawodników ($\text{avg}(\text{time_ms})$) oraz etapy (stage) wykonywanego badania. Etapy badania od 4 do 6 były przeprowadzone bezpośrednio po wykonanym ćwiczeniu (10 przysiadów).

1.4 Interfejsy umożliwiające pozyskanie statystyk graczy z cyfrowego zapisu rozgrywek, odbywających się na własnej infrastrukturze sprzętowo programowej.

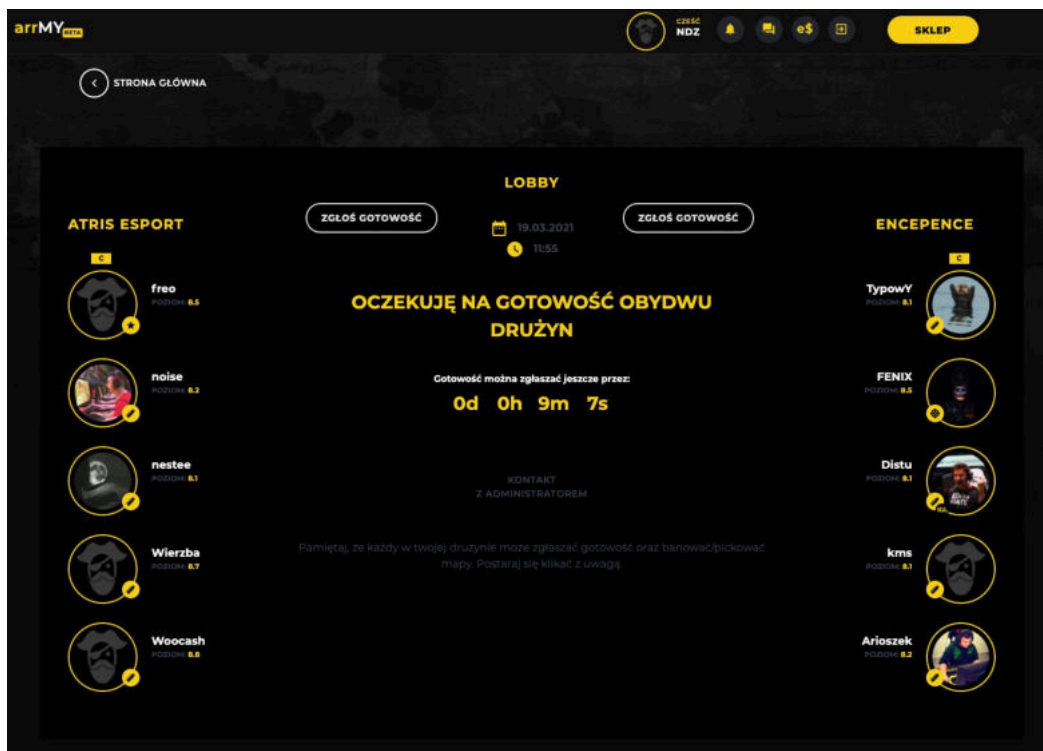
Omawiane w tym punkcie zagadnienie wymagało od nas jednego z największych nakładów pracy. Wszystkie wcześniejsze dane służące do analizy zapisu rozgrywek pozyskiwane były z zewnętrznych serwisów, takich jak: Faceit czy Esportal. Taka sytuacja mogła w przyszłości zamknąć lub znacznie ograniczyć nam drogę do dalszych badań i rozwoju serwisu. Wystarczyłoby unieruchomienie wspomnianych serwisów lub celowe utrudnienie dostępu do ich danych. Z oczywistych powodów nie mogliśmy do tego dopuścić. Efektem naszej pracy jest opisany poniżej zestaw interfejsów dających nam i pośrednio graczom pełną swobodę w tworzeniu, zapisie i analizie danych z meczy co jest podstawą tego projektu.

Rys. 7 Panel laboratorium – umożliwia tworzenie drużyn z dostępnych zawodników



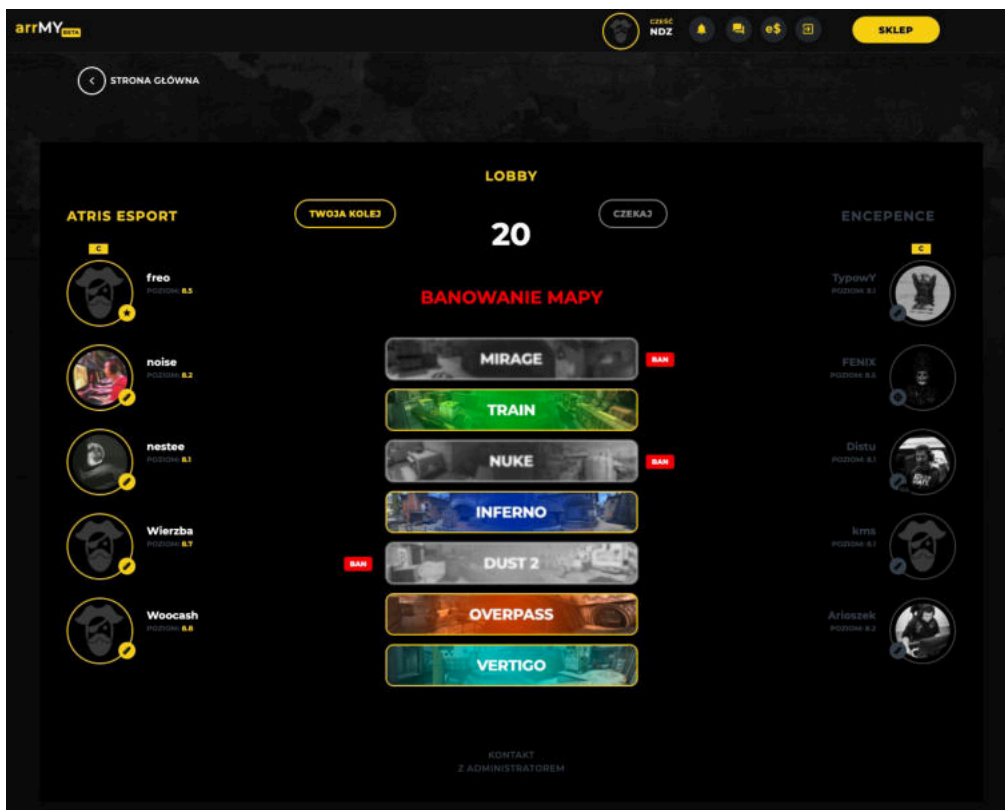


Rys. 8 Panel lobby – umożliwia drużynom synchronizację gotowości do rozegrania meczu

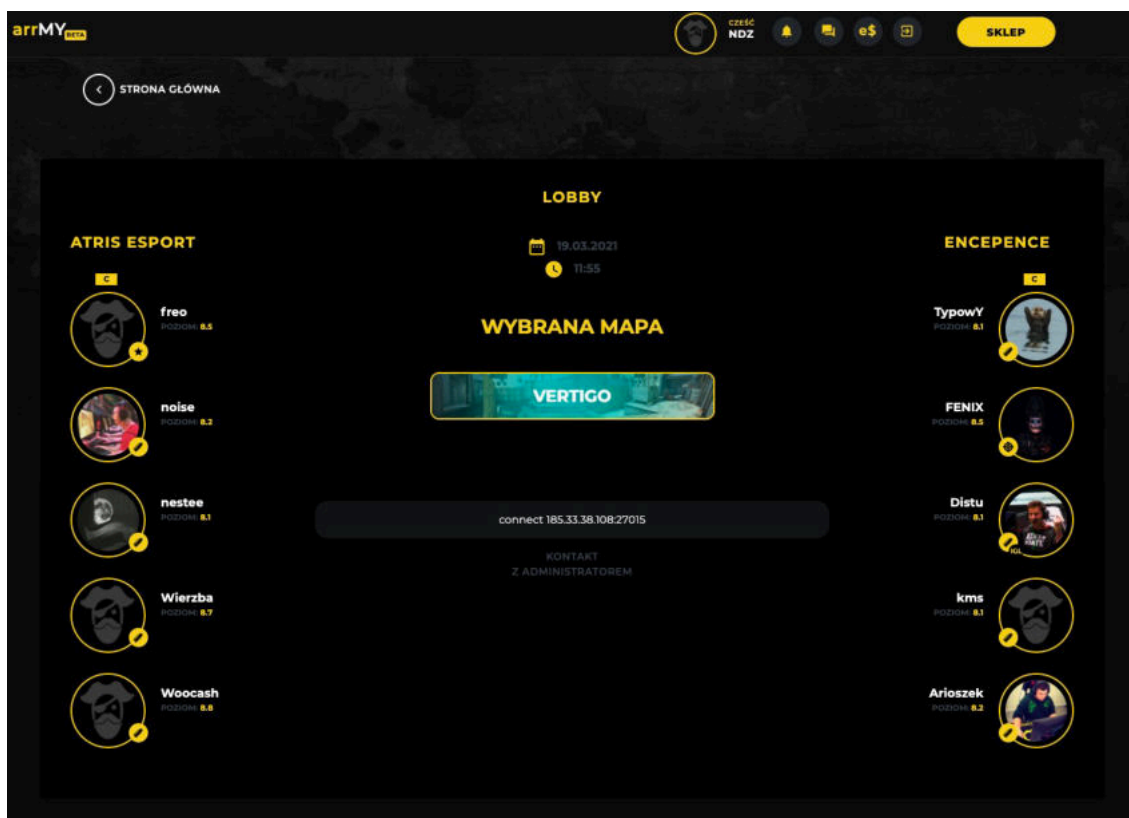


Rys. 9 Panel lobby wariant 2 – umożliwia drużynom wybranie docelowej mapy






Rys. 10 Panel lobby wariant 3 – widok informujący o utworzeniu meczu wraz z lokalizacją serwera na którym odbędzie się rozgrywka



Głównym celem istnienia powyższych interfejsów jest w fazie końcowej rozegranie meczu odbywającego się na naszych serwerach. Jak wspomnieliśmy wcześniej, każdy mecz zostaje zapisany w formie cyfrowej (demo), którą później jesteśmy w stanie zamienić na statystyki graczy. Natomiast statystyki (jak opisano w poprzednich raportach) są bezpośrednim źródłem danych do prac badawczych, między innymi z wykorzystaniem sztucznej inteligencji.

Jednocześnie zrealizowane zostało stworzenie nowych form obserwacji w postaci rozgrywek LAN (offline) w Szczecinie. Zawodnicy przyjechali rozegrać turniej, którego wyniki pokrywały się z predykcjami AI co jednocześnie zrealizowało kamień milowy i pozwoliło przejść do kolejnego etapu projektu.

Rys. 11 Zrzut ekranu z bazy foto z rozgrywek LAN w Netto Arena w Szczecinie



Data realizacji: 05.01.2021

podpisano: Aleksander Kaim



3.5 Do systemu wprowadzone zostaną nowe cechy/system wskazuje przynajmniej jedną drużynę, która osiągnęła wysokie miejsce w turnieju.

1. Do modelu uczenia maszynowego wprowadzamy nowe parametry.

Dotychczas prace badawcze opierały się o dwa główne źródła danych:

- wiedza ekspercka trenerów
- charakterystyki graczy uzyskane z cyfrowego zapisu rozgrywek

Wnioskując z poprzednich raportów - wyniki prac badawczych na bazie powyższych danych okazały się wysoce użyteczne i w pełni spełniały założenia, na których opiera się projekt. Kolejnym ważnym celem było wprowadzenie i analiza nowych parametrów (cech graczy), uzyskanych w wyniku prac psychologów oraz dietetyków (więcej na temat wyniku wspomnianych prac, można przeczytać w załączonych plikach: Raport-dietetyk.pdf, Raportpsycholog.pdf). Poniżej przedstawiamy wykonane zadania, które umożliwiły spełnienie wymagań kamieni milowych etapu VI.

1.1 Uzupelnienie profili przebadanych graczy o cechy predykcyjne wniesione przez psychologów.

Wyniki przeprowadzonych badań psychologicznych (ankiety i ich analiza) zostały dostarczone zespołowi B+R w postaci arkusza kalkulacyjnego (Rys. 1).

Rys. 1 Fragment widoku danych z badań psychologicznych – w formie arkusza kalkulacyjnego.

Wiek	Osobowość					Żwawość	Perseweratywność	Wrażliwość
	Ekstrawersja	Ugodowość	Neurtyczność	Otwartość na doświadczenie	Sumienność			
23	30	42	5	14	35	48	28	
23	45	34	9	22	48	58	41	
20	30	27	18	18	27	47	38	
19	34	36	10	26	38	59	28	
20	22	30	17	22	35	40	40	
22	24	26	21	26	29	52	41	
28	31	25	12	17	36	52	40	
22	28	39	28	25	23	43	44	
17	32	27	16	30	36	45	34	
19	29	25	30	24	29	48	53	
17	34	33	30	25	39	46	43	
21	30	36	14	34	37	48	40	
18	23	34	24	31	34	50	49	
25	28	31	7	18	42	59	25	
21	15	23	32	20	27	54	44	
22	26	32	11	27	32	47	37	
20	37	27	12	32	44	58	39	
21	28	34	2	19	39	49	36	
20	28	34	22	23	37	43	41	
19	36	32	17	26	36	49	48	
21	26	32	17	32	36	50	31	
19	18	26	21	28	33	52	40	
16	27	36	12	24	36	49	35	
21	31	38	5	25	30	56	30	
16	23	30	35	19	20	53	49	
16	25	34	33	22	23	44	48	
20	22	29	24	24	24	46	36	
20	31	41	16	28	43	50	24	
22	32	33	7	34	37	50	37	
16	18	31	17	31	29	56	37	
16	23	25	33	21	22	42	43	
15	30	22	19	27	34	42	31	
17	25	31	9	26	39	51	46	
19	23	35	20	27	23	46	42	
17	26	34	40	28	21	55	51	

Aby uzupełnić profile graczy, powyższe dane zostały przekształcone oraz zaimportowane do bazy danych użytkowników (Rys. 2).

Rys. 2 Fragment widoku bazy danych – dane z badań psychologicznych.

userId	nickname	age	ekstrawersja_osobowosc	ugodowosc_osobowosc	neurtycznosc_osobowosc	otwartoscNaDoswiadczenie_osobo...	sumiennosc_osobowosc	zwawosc_temperament
938	Konradson970	23	30	42	5	14	35	48
945	LuuuQ	23	45	34	9	22	48	58
935	Sirons	20	30	27	18	18	27	47
967	b0lek	19	34	36	10	26	38	59
1020	fenkksdzej	20	22	30	17	22	35	40
973	MikołSlash	22	24	26	21	26	29	52
981	opa'	28	31	25	12	17	36	52
975	Wioster	22	28	39	28	25	23	43
1016	cedrO	17	32	27	16	30	36	45
744	SmQ	19	29	25	30	24	29	48
966	Malazar	17	34	33	30	25	39	46
980	PurpleSesh	21	30	36	14	34	37	48
936	peox	18	23	34	24	31	34	50
1011	kapol	25	28	31	7	18	42	59
964	Nicramo	21	15	23	32	20	27	54
974	Martwy	22	26	32	11	27	32	47
978	KingsMan	20	37	27	12	32	44	58
210	GTLCK	21	28	34	2	19	39	49
989	BarLe	20	28	34	22	23	37	43
998	atoom	19	36	32	17	26	36	49
27	sLicK	21	26	32	17	32	36	50
1006	Zireael	19	18	26	21	28	33	52
970	Kanas	16	27	36	12	24	36	49
972	Thores12	21	31	38	5	25	30	56
591	wik	16	23	30	35	19	20	53
1056	FymoN	16	25	34	33	22	23	44
266	pawkoem	20	22	29	24	24	24	46
1014	jtk	20	31	41	16	28	43	50
413	Ezg0t	22	32	33	7	34	37	50
1047	Kacko	16	18	31	17	31	29	56
971	rize	16	23	25	33	21	22	42
422	HUBI	15	30	22	19	27	34	42
593	Quentoo	17	25	31	9	26	39	51
1052	Staw	19	23	35	20	27	23	46
522	Strike	17	26	34	40	28	21	55

1.2 Uzupełnienie profili przebadanych graczy o cechy predykcyjne wniesione przez dietetyków.

Analogicznie do punktu 1.1 – przekształciliśmy „surowe” dane z badań dietetycznych (Rys. 3) do postaci umożliwiającej ich import do bazy danych (Rys. 4).

Rys. 3 Fragment widoku danych z badań dietetycznych – w formie arkusza kalkulacyjnego.

Wiek	Nawyki żywieniowe	Jakość diety	Stosowanie diety	Suplementacja	Aktywność fizyczna	BMI
23	4,15	-4,03	0	1	1	27,47
23	3,75	-11,89	1	1	3	24,75
20	1,67	-18,92	0	0	2	24,22
19	3,6	3,75	0	1	2	26,3
20	4,3	12,36	0	1	2	34,32
22	3,3	2,69	0	1	1	18,56
28	6,85	15,07	1	1	3	35,75
22	3,93	-5,41	0	0	0	30,15
17	4,65	0,26	1	1	2	19,79
19	2,45	-9,51	0	1	0	24,76
17	2,08	-1,83	0	0	0	24,68
21	3,55	1,62	1	1	0	28,73
18	3,98	4,48	0	1	3	20,45
25	4,65	4,1	0	0	1	23,6
21	2,73	-13,15	0	1	2	21,5
22	3,66	-5,46	0	1	0	19,82
20	4,88	-1,52	0	1	1	22,34
21	2,72	-5,76	0	0	2	20,52
20	3,7	3,35	0	1	1	28,6
19	3,75	-3,4	1	1	1	20,76
21	3,38	2,44	0	0	2	26,54
19	3,55	-8,86	0	0	0	18,52
16	5,38	-3,52	0	0	1	21,15
21	4,35	-3,63	0	1	1	25,18
16	3,15	0,46	0	1	1	21,18
16	2,38	-1,08	0	0	2	28,4
20	4,5	1,45	0	0	0	29,09
20	3	-1,46	0	1	1	18,21
22	4,08	12,32	0	1	1	22,28
16	4,67	11,36	0	0	2	22,16
16	3,28	-6,56	0	0	1	22,89
15	2,1	-9,04	0	0	3	20,76
17	5,45	-6,4	1	1	2	23,18
19	2,43	-6,18	0	0	0	29,39
17	5,1	5,81	0	1	1	22,01
18	3,45	-3,51	0	0	0	20,99
16	5,28	-5,5	0	1	0	32,14

Rys. 4 Fragment widoku bazy danych – dane z badań dietetycznych.

user_id	nickname	age	nawyki_zywieniowe	jakosc_diety	stosowanie_diety	suplementacja	aktywnosc_fizyczna	bmi
938	Konradson970	23	4.15	-4.03	0	1	1	27.47
945	LuuuQ	23	3.75	-11.89	1	1	3	24.75
935	Sirons	20	1.67	-18.92	0	0	2	24.22
967	bOlek	19	3.6	3.75	0	1	2	26.3
1020	feniksdzej	20	4.3	12.36	0	1	2	34.32
973	MikolSlash	22	3.3	2.69	0	1	1	18.56
981	opa'	28	6.85	15.07	1	1	3	35.75
975	Wioster	22	3.93	-5.41	0	0	0	30.15
1016	cedrO	17	4.65	0.26	1	1	2	19.79
744	SmQ	19	2.45	-9.51	0	1	0	24.76
966	Malazar	17	2.08	-1.83	0	0	0	24.68
980	PurpleSesh	21	3.55	1.62	1	1	0	28.73
936	peox	18	3.98	4.48	0	1	3	20.45
1011	kapol	25	4.65	4.1	0	0	1	23.6
964	Nicramo	21	2.73	-13.15	0	1	2	21.5
974	Martwy	22	3.66	-5.46	0	1	0	19.82
978	KingsMan	20	4.88	-1.52	0	1	1	22.34
210	GTLOCK	21	2.72	-5.76	0	0	2	20.52
989	BarLe	20	3.7	3.35	0	1	1	28.6
998	atoom	19	3.75	-3.4	1	1	1	20.76
27	sLicK	21	3.38	2.44	0	0	2	26.54
1006	Zireael	19	3.55	-8.86	0	0	0	18.52
970	Kanas	16	5.38	-3.52	0	0	1	21.15
972	Thores12	21	4.35	-3.63	0	1	1	25.18
591	wik	16	3.15	0.46	0	1	1	23.18
1056	FymoN	16	2.38	-1.08	0	0	2	28.4
266	pawkoem	20	4.5	1.45	0	0	0	29.09

2. Dostrojenie modeli uczenia maszynowego po wprowadzeniu dodatkowych danych.

2.1 Badania na podstawie danych psychologicznych. Dzięki wynikom badań z etapu III (wzór na wartość etykiety rekrutacyjnej Rys. 5) otrzymaliśmy wskaźnik „mocy” danego gracza. To właśnie ta cecha umożliwiła nam stworzenie zestawiania danych (Rys. 6) dla nowego modelu AI, który chcieliśmy przetestować pod kontem siły predykcji w kontekście zestawienia ze sobą cech psychologicznych graczy oraz ich umiejętności. Innymi słowy chcieliśmy sprawdzić na podstawie tylko cech psychologicznych, czy jesteśmy w stanie i z jakim prawdopodobieństwem przewidzieć „moc” danego gracza.

Rys. 5 Wzór na wartość etykiety rekrutacyjnej - Player Power.

$$PP = \frac{norKDR * 4 + norHltvKast * 4 + norDamage * 2 + norKillsNotSeeing * 1}{4 + 4 + 2 + 1}$$



Rys. 6 Fragment widoku bazy danych – zestawienie cech psychologicznych w połączeniu z etykietą rekrutacyjną (Player Power).

nickname	age	Player_Power	ekstrawersja_osobowosc	ugodowosc_osobowosc	neurtycznosc_osobowosc	otwartoscNaDoswiadczenie_osobo...	sumiennosc_osobowosc	zwawosc_temperament
1TAPMcLaren	17	7.151364998138261374	41	46	9	22	38	60
Somsiad	16	6.140511154851377696	36	35	24	26	32	48
Hype-iwnl-	17	6.135398704438666265	26	32	10	33	46	56
Er0	19	6.076959331870117917	35	29	12	23	31	44
j0x	17	5.976323760782850961	30	27	17	18	30	41
mati	18	5.969503816628073178	26	32	17	19	31	49
Protex	18	5.788343692348655408	38	34	13	23	41	41
Seis-	17	5.700346598984606036	29	31	4	21	41	43
pawkoem	20	5.692092721846276916	22	29	24	24	24	46
SiemaSebek	22	5.668677546651711503	25	25	28	20	27	38
m4til	18	5.658123096924565594	27	29	16	27	29	39
EzgoT	22	5.641133341773139684	32	33	7	34	37	50
brajt	18	5.577929991409970858	28	32	37	18	28	44
serek	18	5.468649852691003631	34	35	34	23	19	44
Martwy	22	5.452696453294984506	26	32	11	27	32	47
aldie	20	5.442992942268504720	27	29	18	24	40	55
atoom	19	5.440547017612601924	36	32	17	26	36	49
Betonowy	23	5.429490758743924825	30	35	19	21	30	46
ajyo	21	5.421811378331696242	30	40	7	36	42	39
czaaje	22	5.413764601428372625	20	11	9	15	45	53
GTLCk	21	5.387838715565923140	28	34	2	19	39	49

Ponieważ celem predykcji była cecha Player Power, której wartości należą do liczb wymiernych, jako miarę jakości modelu wybraliśmy współczynnik determinacji (R^2 score). R^2 informuje nas, w jakim procencie zmienność zmiennej zależnej (objaśnianej: Player_Power) jest wyjaśniana za pomocą zmiennej niezależnej (objaśniającej: cechy psychologiczne). Za idealny wynik określa się wartość 1 (im wartość uzyskanego wyniku mniejsza od 1 tym gorzej). W przypadku naszego badania tabela wyników przedstawia się następująco (Rys. 7).

Rys. 7 Lista badanych algorytmów uczenia maszynowego – zawiera wyniki badania danych psychologicznych w postaci współczynnika determinacji (ang. R^2 score). Cel badania: przewidzenie wartości etykiety rekrutacyjnej (PP).

<input type="checkbox"/>	SESSION 1		
<input type="checkbox"/>	Random forest	0.118	☆
<input type="checkbox"/>	Gradient Boosted Trees	-0.138	☆
<input type="checkbox"/>	Ordinary Least Squares	-0.242	☆
<input type="checkbox"/>	Ridge (L2) regression	-0.068	☆
<input type="checkbox"/>	Lasso (L1) regression	-0.079	☆
<input type="checkbox"/>	XGBoost	🏆 0.180	☆
<input type="checkbox"/>	Decision Tree	-0.539	☆
<input type="checkbox"/>	SVM	-0.151	☆
<input type="checkbox"/>	SGD	-0.108	☆
<input type="checkbox"/>	K Nearest Neighbors (k=5)	0.083	☆
<input type="checkbox"/>	Extra trees	-0.089	☆
<input type="checkbox"/>	Artificial Neural Network	-28.723	☆
<input type="checkbox"/>	LASSO-LARS	-0.242	☆



Z powyższego zestawienia (Rys. 7) wynika, że skonstruowane modele nie były w stanie zapewnić wystarczająco zadowalających rezultatów. Niemniej jednak obrany kierunek badania traktujemy rozwojowo, ponieważ zakładamy, że liczebność próby (275 osoby) jaką użyliśmy do testów, będzie systematycznie rosła. Istnieje możliwość, że po przekroczeniu pewnego progu wyniki mogą się poprawić (analiza przedstawiona w raporcie do etapu III, Rys. 8 Krzywa uczenia).

2.2 Badania na podstawie danych dietetycznych.

Analogicznie do działań z punktu 2.1 – postanowiliśmy sprawdzić czy dane dietetyczne są w stanie pomóc w przewidywaniu „mocy” (Rys. 5) gracza. Mając gotowe narzędzia (użyliśmy do ewaluacji wyników tych samych miar co w punkcie 2.1) oraz pomocnicze zestawy danych, uzupełniliśmy modele AI a następnie przeprowadziliśmy badania. Niemniej jednak okazało się - tak jak przypadku danych psychologicznych, że i w tym wypadku, wyniki predykcji są niezadowalające (Rys. 8).

Rys. 8 Lista badanych algorytmów uczenia maszynowego – zawiera wyniki badania danych dietetycznych w postaci współczynnika determinacji (ang. R2 score). Cel badania: przewidzenie wartości etykiety rekrutacyjnej (PP).

SESSION 1			
<input type="checkbox"/>	Random forest	-0.462	☆
<input type="checkbox"/>	Gradient Boosted Trees	-1.412	☆
<input type="checkbox"/>	Ordinary Least Squares	-0.115	☆
<input checked="" type="checkbox"/>	Ridge (L2) regression	🏆 0.023	☆
<input type="checkbox"/>	Lasso (L1) regression	-0.029	☆
<input type="checkbox"/>	XGBoost	-0.703	☆
<input type="checkbox"/>	Decision Tree	-0.397	☆
<input type="checkbox"/>	SVM	-0.005	☆
<input type="checkbox"/>	SGD	-0.109	☆
<input type="checkbox"/>	K Nearest Neighbors (k=5)	-0.310	☆
<input type="checkbox"/>	Extra trees	-0.213	☆
<input type="checkbox"/>	Artificial Neural Network	-33.841	☆
<input type="checkbox"/>	LASSO-LARS	-0.115	☆



3. Zdecydowanie i ewentualne wyłączenie nowych modeli uczenia maszynowego (skorzystanie z innych algorytmów) na podstawie analizy powstałych już modeli dostrojonych do nowych danych.

3.1 Badania na podstawie danych psychologicznych.

Ponieważ badanie opisane w punkcie 2.1 nie wniosło do projektu ARRMY realnej wartości biznesowej, postanowiliśmy nie dać za wygraną. Chcieliśmy znaleźć zadowalające zastosowanie dla wysiłków i pracy wykonanej przez psychologów. Nasze podejście bardzo się opłaciło. Po wielu przemyśleniach i testach okazało się, że dzięki badaniom psychologicznym w połączeniu ze sztuczną inteligencją, jesteśmy w stanie pomóc graczom w trudnej decyzji, o wyborze roli (pozycji), jaką będą pełnić w zespole. Mamy tu na myśli wybór pomiędzy:

- IGL - Lider (ang. IGL - In Game Leader)
- AWP - Snajper (AWP – od nazwy broni snajperskiej)
- Rifler - Szturmowiec (osoba posługująca się karabinami szturmowymi)
- IGL + AWP (lider drużyny posługujący się bronią snajperską)

Najlepsze wyniki otrzymaliśmy zestawiając między sobą role AWP oraz Rifler'a. Aby przeprowadzić wspomniane badanie, stworzyliśmy zestaw danych (Rys. 9) składający się z cech psychologicznych oraz roli jaką pełnią gracze.

Rys. 9 Fragment widoku zbioru danych – zestawienie cech psychologicznych oraz roli jaką pełnią gracze. Następnie, do procesu uczenia modeli AI, dobraliśmy graczy o najwyższym PP (Player

nickname	age	role	ekstrawersja_osobowosc	ugodowosc_osobow...	otwartoscNaDoswiadcze...	neurtycznosc_osobowosc
string Text	bigint Integer	string Text	bigint Integer	bigint Integer	bigint Integer	bigint Integer
cheethy	20	AWP	32	35	29	14
xlight	22	AWP	31	34	27	13
Rider	19	AWP	28	38	25	14
bulkeN1k	19	AWP	32	27	25	16
Coledame1	15	AWP	25	28	24	23
Konradson970	23	Rifler	30	42	14	5
LuuuQ	23	Rifler	45	34	22	9
Sirons	20	Rifler	30	27	18	18
b0lek	19	Rifler	34	36	26	10
feniksdzej	20	Rifler	22	30	22	17

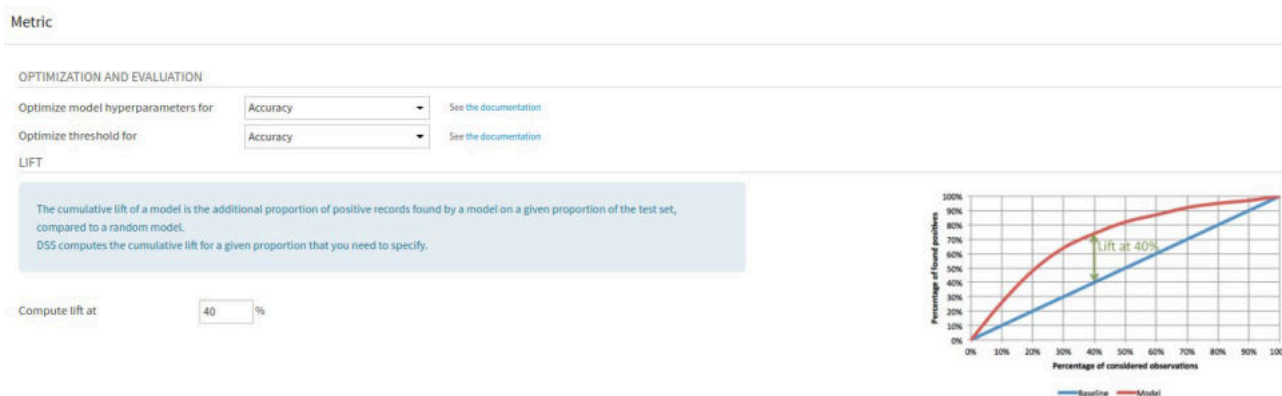
Następnie, do procesu uczenia modeli AI, dobraliśmy graczy o najwyższym PP (Player Power) wychodząc z założenia: Zawodnik osiągający bardzo dobre wyniki w grze, musiał wcześniej dobrać swoją rolę w sposób wysoce optymalny. Jak pokazują poniższe wyniki predykcji wyuczonych modeli (Rys. 10), założenie to okazało się zasadne. Otrzymaliśmy aż 73% trafnych predykcji, które zapewnił model drzew losowych (ang. random forest). Ponieważ celem predykcji była tylko jedna cecha (rola gracza), której wartość można przedstawić na dwa sposoby (AWP / Rifler), mogliśmy do oceny jakości klasyfikacji modelu, wybierać spośród kilku opcji np.: F1 Score, Accuracy, Precision, Recall, AUC itp. Wybór padł na metrykę jaką jest precyzja (ang. accuracy, Rys. 11).



Rys. 10 Lista badanych algorytmów uczenia maszynowego – zawiera wyniki przewidywania roli gracza w postaci precyzji (ang. Accuracy).

<input type="checkbox"/> SESSION 5			
<input type="checkbox"/>	Random forest	🏆 0.731	☆
<input type="checkbox"/>	Gradient Boosted Trees	0.654	☆
<input type="checkbox"/>	Logistic Regression	0.615	☆
<input type="checkbox"/>	XGBoost	0.577	☆
<input type="checkbox"/>	Decision Tree	0.692	☆
<input type="checkbox"/>	K Nearest Neighbors (k=5)	0.654	☆
<input type="checkbox"/>	Extra trees	0.654	☆
<input type="checkbox"/>	Artificial Neural Network	0.692	☆
<input type="checkbox"/>	SVM	0.538	☆
<input type="checkbox"/>	SGD	0.692	☆
<input type="checkbox"/>	LASSO-LARS	🏆 0.731	☆

Rys. 11 Wybrana metryka - precyzja (ang. Accuracy) - do oceny jakości klasyfikacji.



Celem każdego z algorytmów było wytypowanie roli (Rys. 12 - „role”) z możliwie największym prawdopodobieństwem. Aby zapewnić dobrze zbalansowany zestaw danych uczących (Rys. 9), zmodyfikowaliśmy go w taki sposób, że liczebność ról (AWP, Rifler) występowała w proporcji 50:50% (Rys. 12).

Rys. 12 Widok celu (roli – AWP lub Rifler) algorytmów uczenia maszynowego.

Target

Prediction type: Two-class classification RE-DETECT SETTINGS

Target: role

PARTITIONED MODELS

Partitioning Not available: input dataset is not partitioned.

TARGET CLASSES

Proportions of classes in the guess sample

Class	Proportion
AWP	50%
Rifler	50%

Podsumowując powyższe badanie. Otrzymaliśmy model uczenia maszynowego, który jest w stanie podpowiedzieć (z 73% pewnością) niezdecydowanym graczom, jaka rola (AWP czy Rifler) będzie do nich lepiej pasowała. Model bazuje na wynikach testu psychologicznego co jest jego niewątpliwą zaletą, gdyż nie jest wymagane aby zawodnik rozegrał jakikolwiek mecz (nie potrzebujemy cyfrowego zapisu rozrywki) dzięki czemu, możliwa jest oszczędność czasu i zasobów.

3.2 Badania na podstawie danych dietetycznych.

Poniżej przedstawiamy zestawienie przeprowadzonych prac, w celu odnalezienia użytecznych zastosowań dla danych dotyczących zwyczajów dietetycznych badanej próby:

- Badanie algorytmami uczenia maszynowego w celu przewidzenia etykiety rekrutacyjnej (Player Power) – wynik niezadowolający (Rys. 8).
- Badanie algorytmami uczenia maszynowego w celu przewidzenia stopnia refleksu – wynik niezadowolający (Rys. 13).



Rys. 13 Lista badanych algorytmów uczenia maszynowego – zawiera wyniki przewidywania stopnia refleksu gracza w postaci współczynnika determinacji (ang. R2 score).

SESSION 1		
<input checked="" type="checkbox"/>	Random forest	0.004 ☆
<input type="checkbox"/>	Gradient Boosted Trees	-0.078 ☆
<input type="checkbox"/>	Ordinary Least Squares	-0.058 ☆
<input type="checkbox"/>	Ridge (L2) regression	-0.030 ☆
<input type="checkbox"/>	Lasso (L1) regression	-0.024 ☆
<input type="checkbox"/>	XGBoost	-0.081 ☆
<input type="checkbox"/>	Decision Tree	-0.186 ☆
<input type="checkbox"/>	SVM	-0.078 ☆
<input type="checkbox"/>	SGD	-0.058 ☆
<input type="checkbox"/>	K Nearest Neighbors (k=5)	-0.020 ☆
<input type="checkbox"/>	Extra trees	🏆 0.004 ☆
<input type="checkbox"/>	Artificial Neural Network	-8.030 ☆
<input type="checkbox"/>	LASSO-LARS	-0.058 ☆

Jak pokazują powyższe wyniki, algorytmy AI w połączeniu z danymi dietetycznymi, nie były w stanie przybliżyć nas do przewidzenia szukanych zmiennych. Niemniej jednak postanowiliśmy sprawdzić, czy wspomniane dane mogą wskazać jakieś pożyteczne zależności, między pozostałymi zbiorami danych jakimi dysponowaliśmy. Najbardziej obiecujące wyniki dało poszukiwanie korelacji między psychiką graczy a ich nawykami żywieniowymi i ruchowymi (Rys. 14, 15 i 16).

Rys. 14 Korelacje zmiennej aktywność fizyczna.

Pearson correlation		
N aktywnosc_fizyczna		
Filter ...		
1	+0.518	aktywnosc_fizyczna
2	+0.400	aktywnosc_fizyczna
3	+0.396	aktywnosc_fizyczna
4	+0.340	aktywnosc_fizyczna
5	+0.298	aktywnosc_fizyczna
6	+0.297	aktywnosc_fizyczna
7	+0.267	aktywnosc_fizyczna
8	+0.254	aktywnosc_fizyczna
9	+0.250	aktywnosc_fizyczna
10	+0.248	aktywnosc_fizyczna
		aktywnosc_temperament
		ekstrawersja_osobowosc
		silaWoli_nadziejaNaSukces
		poszukiwanieKontaktowTowarzyskich_styleRadzeniaSobieZeStr...
		optymizm
		sumiennosc_osobowosc
		wytrzymalosc_temperament
		poczucieSkuteczności
		stylSkoncentrowanyNaZadaniu_styleRadzeniaSobieZeStresem
		motywacjaOsiagniec

Rys. 15 Korelacje zmiennej jakość diety.

Pearson correlation		
N jakosc_diety		
Filter ...		
1	+0.412	jakosc_diety nawyki_zywieniowe
2	+0.266	jakosc_diety sumiennosc_osobowosc
3	+0.238	jakosc_diety poszukiwanieKontaktowTowarzyskich_styleRadzeniaSobieZeStr...
4	+0.234	jakosc_diety otwartoscNaDoswiadczenie_osobowosc
5	+0.228	jakosc_diety planowanie_radzenieSobieZeStresemCope
6	+0.228	jakosc_diety motywacjaOsiagniec
7	+0.219	jakosc_diety silaWoli_nadziejaNaSukces
8	+0.207	aktywnosc_temperament jakosc_diety
9	+0.205	jakosc_diety optymizm
10	+0.204	aktywnosc_fizyczna jakosc_diety

Rys. 16 Korelacje zmiennej nawyki żywieniowe.

Pearson correlation		
N nawyki_zywieniowe		
Filter ...		
1	+0.412	jakosc_diety nawyki_zywieniowe
2	+0.363	nawyki_zywieniowe rytmicznosc_temperament
3	+0.273	motywacjaOsiagniec nawyki_zywieniowe
4	+0.266	nawyki_zywieniowe sumiennosc_osobowosc
5	+0.259	nawyki_zywieniowe silaWoli_nadziejaNaSukces
6	+0.218	nawyki_zywieniowe stylSkoncentrowanyNaZadaniu_styleRadzeniaSobieZeStresem
7	+0.217	nawyki_zywieniowe optymizm
8	-0.216	nawyki_zywieniowe zaprzestanieDzialan_radzenieSobieZeStresemCope
9	+0.205	aktywnosc_temperament nawyki_zywieniowe
10	+0.202	nawyki_zywieniowe poczucieSkuteczności

Na podstawie powyższych korelacji, jesteśmy w stanie uzyskać wartość biznesową. Na przykład dla cech aktywność/temperament a ekstrawersja (Rys. 14), poziom istotności p dla dodatniej korelacji Pearsona przy liczności badanej próby (275 osób) wynosi $p < 0,001$. Wynik świadczy o tym, że korelacja jest istotna statystycznie. Skoro w przebadanej grupie istnieje zależność między aktywnością/temperamentem a poziomem ekstrawersji, to daje nam to możliwość tworzenia pewnych rekomendacji dla graczy. Moglibyśmy np. zaproponować przebadanym - którzy otrzymali niższy niż średni wynik dla ekstrawersji - następującą rekomendację: Wyniki Twojego testu psychologicznego wskazują na niższy niż średni (wśród przebadanych graczy) poziom ekstrawersji, co może sugerować potrzebę zwiększenia Twojej aktywności fizycznej. Jeśli jednak jesteś osobą aktywną fizycznie zignoruj proszę tą rekomendację.



Jak widać z powyższego przykładu – badania przyczyniły się do tego, że wykonując tylko same testy psychologiczne, jesteśmy w stanie (z umiarkowanym prawdopodobieństwem) wnioskować np. o predyspozycjach do zaniechań w sferze aktywności fizycznej. To bardzo cenna wiedza, z której na pewno skorzystają gracze, ich trenerzy oraz cały projekt ARRM.

Powyższe powoduje realizację kamienia milowego i przejście do kolejnego etapu projektu.

Data realizacji: do 31.01.2021

podpisano: Aleksander Kaim

3.6 Zaprezentowanie zestawu cech, który daje najlepsze drużyny esportowe.

W ramach tego etapu zespół techniczny opracował szereg widoków (generowanych na serwerze), które można przeglądać za pośrednictwem każdej popularnej przeglądarki internetowej (np. Chrome, Firefox, Microsoft Edge, Safari, Opera itp.). Warto podkreślić, że nie jest to „zlepek” przypadkowych stron www. Wspomniane interfejsy tworzą logiczną całość - budując w pełni zintegrowany, intuicyjny system analizy i zarządzania rozgrywką, drużynami oraz indywidualnymi graczami. Poniżej przedstawiamy najważniejsze widoki służące prezentacji cech tworzących najlepsze drużyny i zawodników.

1. Opracowanie narzędzi umożliwiających przejrzyste prezentowanie w systemie, jakie cechy oraz ich połączenia dają najlepszych graczy.

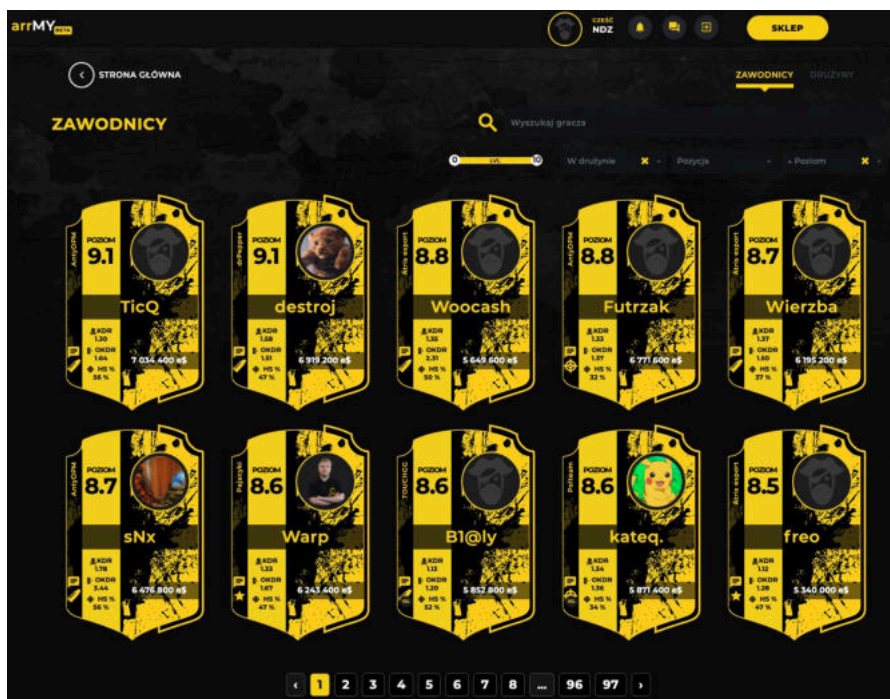
Poniższy interfejs (Rys. 1) pozwala na prezentację wszystkich zawodników biorących czynny udział w rozgrywkach. Sposób prezentacji jest bardzo intuicyjny, precyzyjny i przede wszystkim skuteczny w szybkim wyszukiwaniu informacji, dzięki takim funkcjom jak:

- filtrowanie po pozycji (IGL, Rifler, AWP, IGL+AWP)
- filtrowanie po poziomie gracza
- filtrowanie po statusie (w drużynie, brak drużyny, poszukujący drużyny)

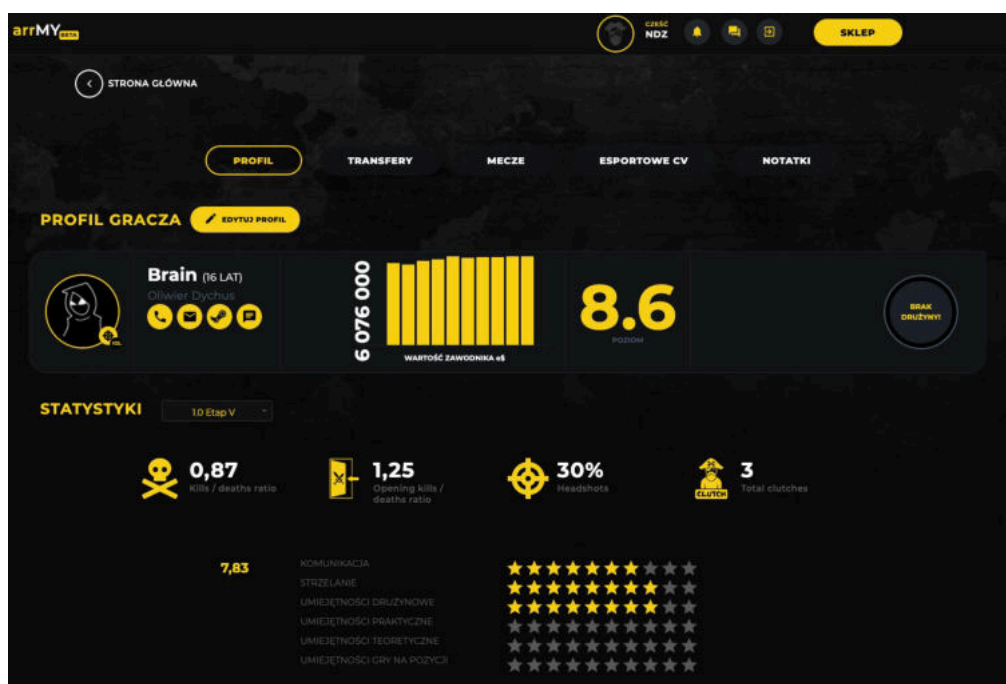
Każdy zawodnik opisany jest przez wybrany zestaw cech KDR, OKDR, HS (Rys. 1), które mają wpływ na zajmowaną przez niego pozycję. Nie mniej zestaw informacji nie ogranicza się tylko do wyżej wspomnianych charakterystyk, ponieważ po kliknięciu w „kartę zawodnika” zostaniemy przeniesieni do kolejnego widoku gdzie można przeanalizować dużo większy zakres danych na temat danego gracza (Rys. 2).



Rys. 1 Panel zawodników - widok kart z najistotniejszymi cechami graczy.



Rys. 2 Panel zawodnika - szczegółowy widok charakterystyk gracza.



Powyższy panel agreguje wszystkie najistotniejsze charakterystyki jakie mają wpływ na poziom danego gracza:



- Wartość (przedstawiana w wirtualnej walucie platformy – e\$ czyt. esports dollars)
- Poziom
- Kill / death ratio
- Opening kill / death ratio
- Headshots
- Total clutches
- Poziom kluczowych umiejętności: komunikacja, strzelanie, umiejętności drużynowe, umiejętności praktyczne, umiejętności teoretyczne, umiejętności gry na pozycji

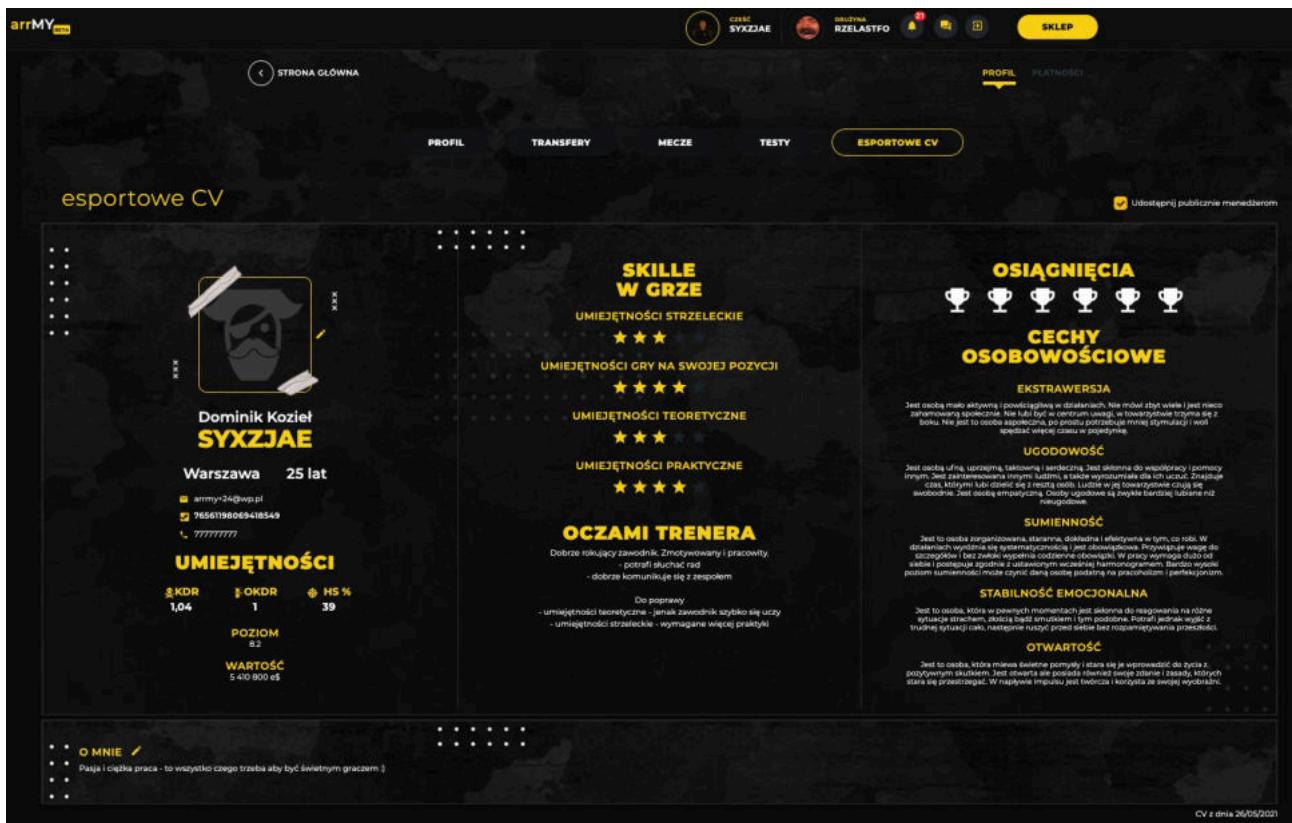
Bardzo ważne jest to, że wspomniane wskaźniki są dynamiczne. Innymi słowy zmieniają się w czasie wraz z postępem kariery danego zawodnika. Tak jak w życiu – gracze mogą reprezentować raz lepszą raz gorszą formę, czego odzwierciedleniem jest np. historyczny zapis „Wartości” gracza, przedstawiony za pomocą wykresu słupkowego. Dzięki temu mamy nie tylko informację o aktualnej formie gracza, ale i o trendzie (zwyżka / niżka formy), w jakim się znajduje.

Dodatkowo z panelu zawodnika (Rys. 2) użytkownik ma bezpośredni dostęp do miejsca gdzie, można obejrzeć specjalnie wygenerowane „esportowe CV” (Rys. 3), które w przejrzysty sposób obrazuje jego osiągnięcia w ścieżce kariery gracza e-sportowego. W CV znalazły się następujące charakterystyki:

- KDR, OKDR, HS
- Poziom
- Wartość (w esports dolarach e\$)
- Umiejętności strzeleckie
- Umiejętność gry na swojej pozycji
- Umiejętności teoretyczne
- Umiejętności praktyczne
- Oczami trenera (podsumowanie gracza oczami trenera)
- Osiągnięcia
- Opis cech osobowościowych (na bazie badań psychologicznych): ekstrawersja, ugodowość, sumienność, stabilność emocjonalna, otwartość



Rys. 3 Esportowe CV gracza.



Kolejnym interfejsem (widocznym tylko dla trenerów) jest tabelaryczny widok graczy (Rys. 4). Narzędzie to posiada zestaw przydatnych filtrów, które znacznie upraszczają odnalezienie i edytowanie danych zawodników o konkretnych cechach np. poziomie, średniej oceny, statusie, etapu rozgrywek, sezonu, pozycji itp.

Rys. 4 Panel zawodników – widok tabelaryczny – dostępny tylko dla trenerów.

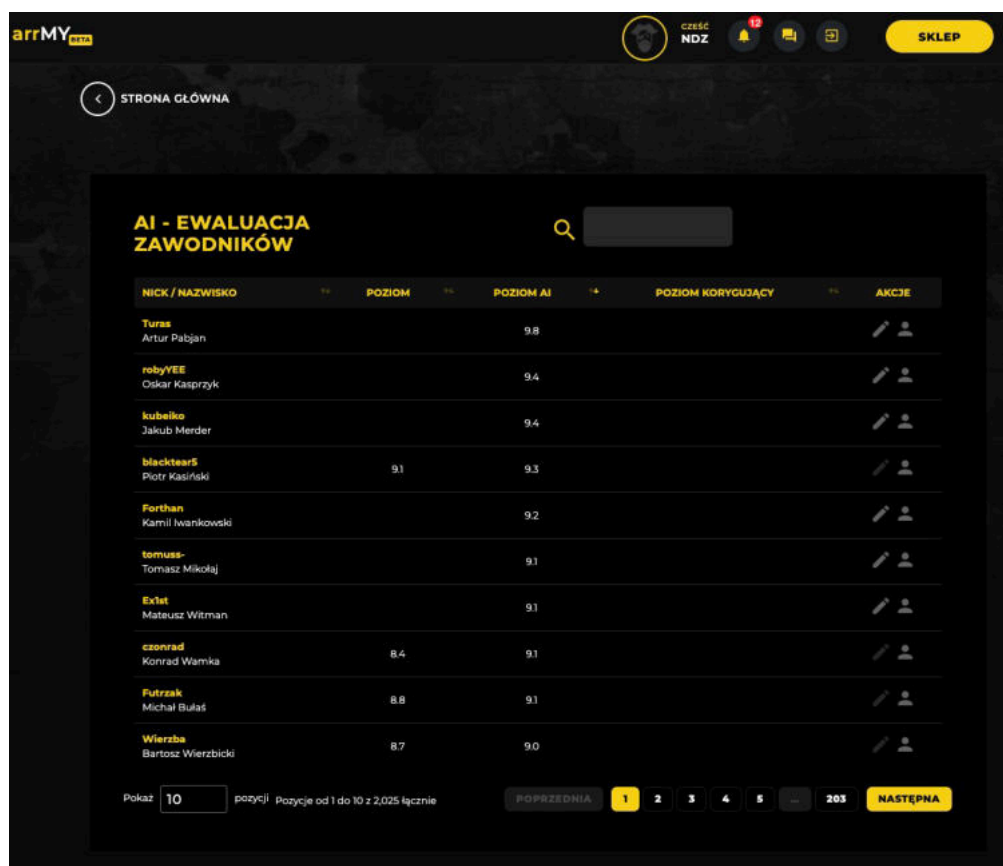
ZAWODNICZY

AKCJE NICK NAZWISKO POZYCJA WIEK DRUŻYNY SEZON ETAP STATUS ZAKOŃCZONE MECZE DATA MECZU POZIOM ŚR. OCENY + ŚR. OCENY ETAPU

spławik	Lukasz Jahn	IGL	20	ex-piratesports	2I	Army Teams	Oczekiwanie na następną rozgrywkę	10 + 0		9,83	0,00	10 III-9,83
fr3nd	Sebastian Kuźmierz	AWP	18		1,0	Etap IV	Brak kontaktu	0 + 0		9,50	0	10 III-9,5
destroj	Maciej Deorocki	Rifler	23	drPepper	2I	Army Teams	Oczekiwanie na następną rozgrywkę	4 + 0	91	9,00	0,00	10 III-9 10 IV-9,33 10 V-8,67 2,0 Wer-9
Refludo	Piotr Bączek	Rifler MINI-IGL	20	Konsarze	2I	Army Teams	Oczekiwanie na następną rozgrywkę	13 + 0	82	9,00	0,00	2,0 Wer-9
Ortel	Patryk Ortel	Rifler	25		1,0	Etap IV	Rezygnacja z projektu	2 + 0		8,91	9,17	10 III-7,99 10 V-9,67
Alask	Michał Pręciuk	Rifler	22		1,0	Etap IV	Nieznamy	0 + 0		8,83	0	10 III-8,83
Wooosh	Lukasz Olszowski	Rifler	21	Atria esport	2I	Army Teams	Oczekiwanie na następną rozgrywkę	13 + 0	8,8	8,83	0,00	10 III-8,83 10 IV-8,5 10 V-9,33 2,0 Wer-8,67
piiter	Piotr Kubiak	IGL	20		1,0	Etap V	Oczekuje na dalsze decyzje trenerów	2 + 0		8,67	8,67	10 III-9 10 IV-8,67

System zapewnia jeszcze jeden widok (Rys. 5) dostępny tylko dla trenerów lub inwestorów. Jest to miejsce w którym można podejrzeć ewaluację graczy uzyskaną w procesie przetwarzania danych za pośrednictwem algorytmów sztucznej inteligencji (AI).

Rys. 5 Panel zawodników – widok ocen wystawianych przez algorytmy uczenia maszynowego.



NICK / NAZWISKO	POZIOM	POZIOM AI	POZIOM KORYGUJĄCY	AKCJE
Turas Artur Pabjan		9,8		
robYVEE Oskar Kasprzyk		9,4		
kubelko Jakub Merder		9,4		
blacktear5 Piotr Kasirski	9,1	9,3		
Forthan Kamil Iwankowski		9,2		
tomuss- Tomasz Mikolaj		9,1		
Exist Mateusz Witman		9,1		
czonrad Konrad Wamka	8,4	9,1		
Futrzak Michał Bulaś	8,8	9,1		
Wierzba Bartosz Wierzbicki	8,7	9,0		

W projekcie arrMY gracze są zawsze na pierwszym miejscu – to głównie na nich skupia się większość dostępnych funkcjonalności. Niemniej jednak bardzo ważnym elementem systemu są również trenerzy. To do nich należy ostateczna ewaluacja zawodników i prowadzenie drużyn. Zespół tworzący arrMY zdał sobie sprawę, że nie tylko ocena zawodników ma wartość biznesową. Założyliśmy, że przyszły inwestor - budujący drużynę - chętnie zatrudniłby również trenera. Właśnie z tego powodu stworzyliśmy mechanizm umożliwiający ocenianie pracy trenerów. W tym wypadku to jednak zawodnicy wystawiają oceny (Rys. 6).

Dzięki temu mamy większą pewność, że wspomniane metryki są maksymalnie wiarygodne. Na poniższym widoku możemy zaobserwować następujące elementy:

- Podejście do zawodnika
- Umiejętność wyjaśniania błędów
- Poziom kultury osobistej
- Średnia wszystkich ocen oraz data wystawienia



W widoku szczegółowym występuje dodatkowo:

- Identyfikator wystawiającego ocenę
- Mecz po którym została wystawiona ocena

Rys. 6 Panel trenerów – widok ocen wystawianych trenerom przez graczy.

NICK NAZWISKO	ŚR. PODEJŚCIE DO ZAWODNIKA	ŚR. WYJASNIENIE BŁĘDÓW	ŚR. KULTURA OSOBISTA	ŚR. WSZYSTKICH OCEN	DATA OSTATNIEJ OCENY
Kuba Kubiak Kubiak	4.99	4.91	4.99	4.96	08/04/2023 08:18 czw
Wojciech Jaworski Fiser	4.90	4.73	4.98	4.87	18/02/2021 23:03 czw
Marcin Klusek Klusek	4.72	4.67	4.88	4.69	26/01/2021 20:56 wt
Bartłomiej Cawias BICO	4.94	4.82	4.98	4.91	19/08/2020 10:07 śr

NICK NAZWISKO	PODEJŚCIE DO ZAWODNIKA	WYJASNIENIE BŁĘDÓW	KULTURA OSOBISTA	DATA OCENY	MECZ
Lukasz Styrzecki stsr	★★★★★	★★★★★	★★★★★	19/08/2020 10:07 śr	19/08/2020 18:00 wt
Lukasz Pachucki mexby	★★★★★	★★★★★	★★★★★	16/07/2020 23:20 czw	16/07/2020 18:00 czw
Lukasz Pachucki mexby	★★★★★	★★★★★	★★★★★	18/08/2020 21:21 wt	18/08/2020 18:00 wt
Lukasz Macieja Lukaszmac07	★★★★★	★★★★★	★★★★★	25/06/2020 21:31 czw	25/06/2020 18:00 czw
Wojtek Demicki Demia	★★★★★	★★★★★	★★★★★	10/06/2020 22:39 czw	10/06/2020 18:00 czw
Wojciech Duda benary	★★★★★	★★★★★	★★★★★	10/08/2020 17:43 śr	10/08/2020 18:00 wt
Wiktor Lachowicz TRQ	★★★★★	★★★★★	★★★★★	15/07/2020 22:39 śr	15/07/2020 18:00 pon
Wiktor Lachowicz TRQ	★★★★★	★★★★★	★★★★★	18/06/2020 21:39 czw	18/06/2020 18:00 czw

2. Stworzenie interfejsu umożliwiającego prezentację, jakie cechy oraz ich połączenia dają najlepsze drużyny e-sportowe.

W pierwszej części raportu (punkt 1) omówiliśmy interfejsy odpowiedzialne za prezentację indywidualnych graczy. Natomiast w tym punkcie przedstawimy widoki prezentujące potencjał drużyny. Jest to bardzo istotna funkcjonalność ponieważ zbudowanie jak najlepszych drużyny będzie głównym celem inwestorów.

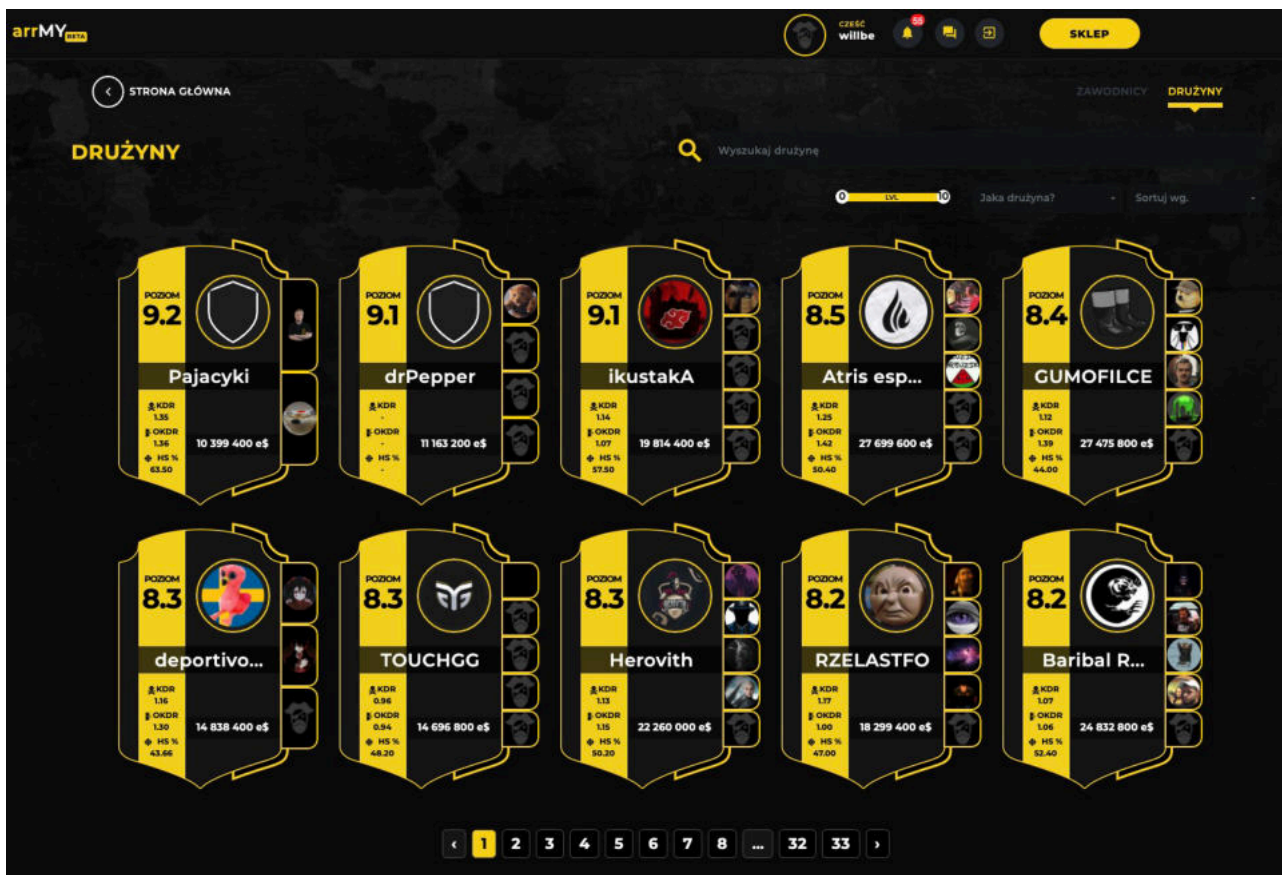
Projektując platformę arrMY staraliśmy się, aby nawigowanie po widokach drużyn było maksymalnie podobne do sposobu, w jaki przegląda się zawodników. Dzięki temu uspójniliśmy nawigację, co pozytywnie wpłynęło na intuicyjność serwisu. Analogicznie do punktu 1 niniejszego raportu – pierwszy widok (Rys. 7) pozwala na prezentację wszystkich drużyn biorących czynny udział w rozgrywkach. Zachowaliśmy intuicyjny i wygodny sposób prezentacji, aby użytkownik jak najszybciej znalazł interesujące go informacje:

- Poziome drużyny
- KDR
- OKDR




- HS
- Skład
- Kondycja finansowa (widoczne tylko dla użytkowników z najwyższymi prawami dostępu)

Rys. 7 Panel drużyn - widok kart z najistotniejszymi cechami składów.



Po kliknięciu w jedną z powyższych kart użytkownik zostaje przeniesiony do widoku prezentującego szczegóły wybranej drużyny (Rys. 8).

Rys. 8 Panel drużyny - szczegółowy widok charakterystyk i członków zespołu.



W tym miejscu należy wspomnieć, że widok przedstawiony na (Rys. 8) jest dostępny w dwóch wariantach – z widocznym stanem konta lub ukrytym. Pierwszy, który prezentujemy powyżej może zobaczyć użytkownik z prawami dostępu na poziomie trenera lub członek drużyny. Dzięki temu możliwe jest np. sprawdzenie aktualnej kondycji finansowej – poziomu wirtualnej waluty wyrażanej w esport dolarach (e\$). Jest to cenna informacja, bo mówi nam jak drużyna radzi sobie nie tylko w takich zagadnieniach jak wygrywanie meczy (zarabia), ale również planowania transferów graczy czy ogólnie pojętej umiejętności zarządzania finansami.

Oczywiście oprócz finansów, można w tym miejscu sprawdzić:

- Poziom drużyny
- Średni wiek zawodników
- Średnie umiejętności drużynowe
- Średni stosunek zabójstw do poniesionych śmierci (ang. Kill/Death ratio)
- Średni stosunek zabójstw do poniesionych śmierci w pierwszej fazie rundy (ang. opening Kill/Death ratio)
- Średnią wartość strzałów w głowę (ang. headshots)

Kolejnym interfejsem (widocznym tylko dla trenerów) jest tabelaryczny widok drużyn (Rys. 9). Narzędzie to posiada zestaw przydatnych filtrów, które znacznie upraszczają odnalezienie zespołów o konkretnych cechach:

- AI/AI2 PRED. - jeden z najważniejszych i najbardziej zaawansowanych technologicznie wskaźników – jest to przewidywany poziom wygralności drużyny oparty o wyliczenia algorytmów sztucznej inteligencji. Najwyższa badana skuteczność przewidywania wygranej w realnym turnieju osiągnęła jak dotąd poziom 78% trafnych predykcji.

- Wygrane mecze
- Czas gry
- Składy
- Bieżące mecze
- Data kolejnego meczu
- Czy drużyna ma status „menedżerska” – czyli czy jest prowadzona przez podmiot biznesowy np. firmę chcącą mieć własną drużynę esportową.



Rys. 9 Panel drużyn - widok tabelaryczny – dostępny tylko dla trenerów.

	NAZWA	MENEDŻERSKA	AI PRED.	AG PRED.	CZAS CRY	SKŁADY	SKŁAD PODSTAWOWY	MECZE ZAKOŃCZONE	WYGRANE	MECZE BIEŻĄCE	DATA KOLEJNEGO MECZU	
	Pajacyki		100.00%	97.91%		2	✓ 2	2				
	Jadoopie		100.00%	96.58%		7	✓ 2	34				
	ADHD		99.39%	98.93%		3	✓ 5	18				
	Łyski z Brazzera		95.24%	92.58%		8	✓ 5	10				
	Kazuare Squad		92.24%	70.50%		6	✓ 1	10				
	whatever		87.88%	85.71%		8	✓ 1	18				
	Totalnem!		80.52%	83.12%		3	✓ 3	12				
	Minionki Gaming		73.82%	63.20%		5	✓ 2	10				
	Team MCE		73.29%	64.50%		7	✓ 3	21				
	Ledis Academy by IHG		65.88%	50.74%		7	✓ 5	10				

3. Stworzenie narzędzi umożliwiających trenerom i psychologom dawanie wytycznych graczom do samodoskonalenia się. Umożliwienie graczom dostępu do tych wytycznych.

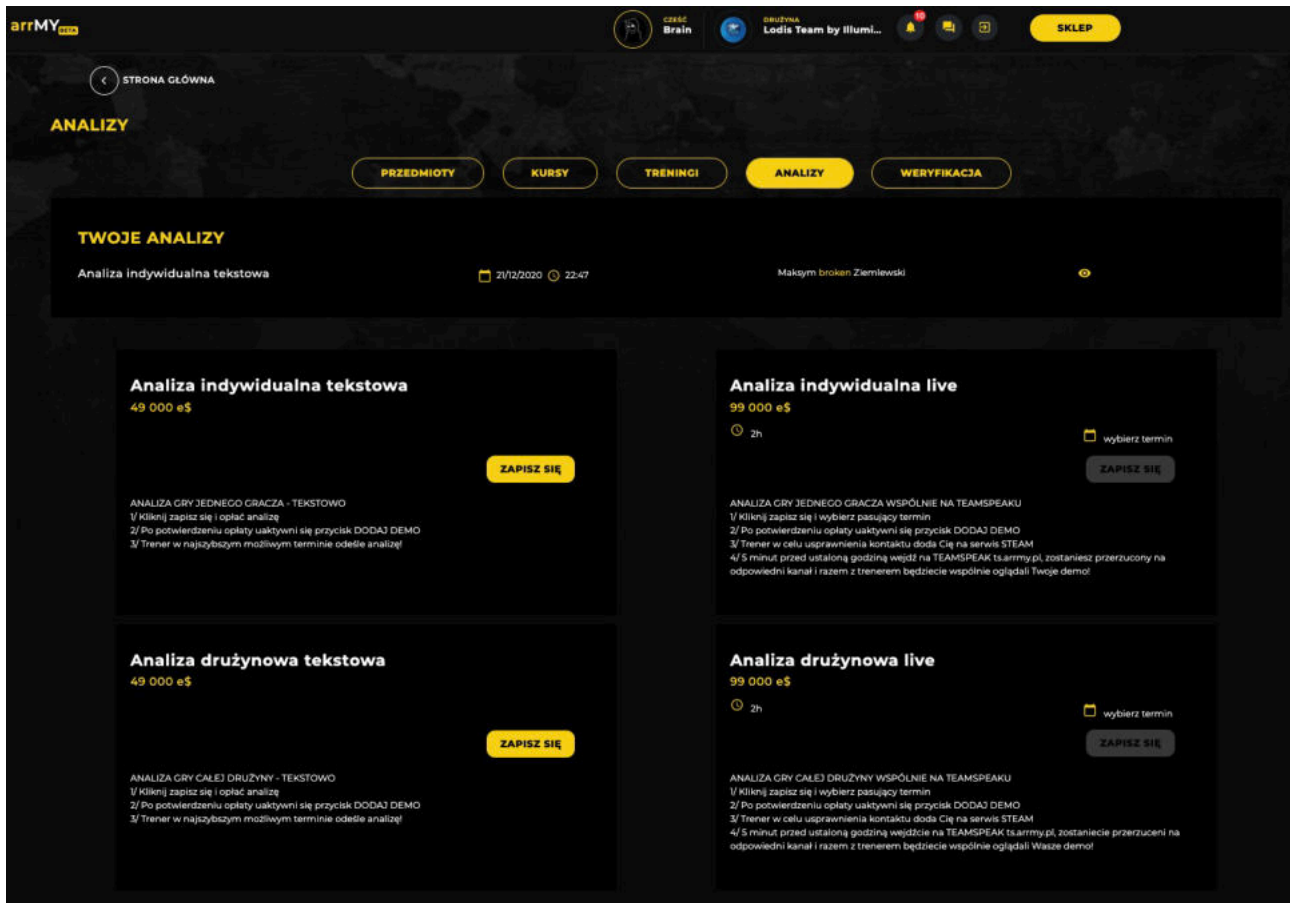
Ostatnim zadaniem w etapie VII było stworzenie intuicyjnych i dobrze zorganizowanych narzędzi umożliwiających komunikację (w tym wytyczne) między graczami i dbającymi o rozwój ich kariery ekspertami (trenerzy, psychologowie, managerowie itp.).

3.1 Narzędzia dla trenerów.

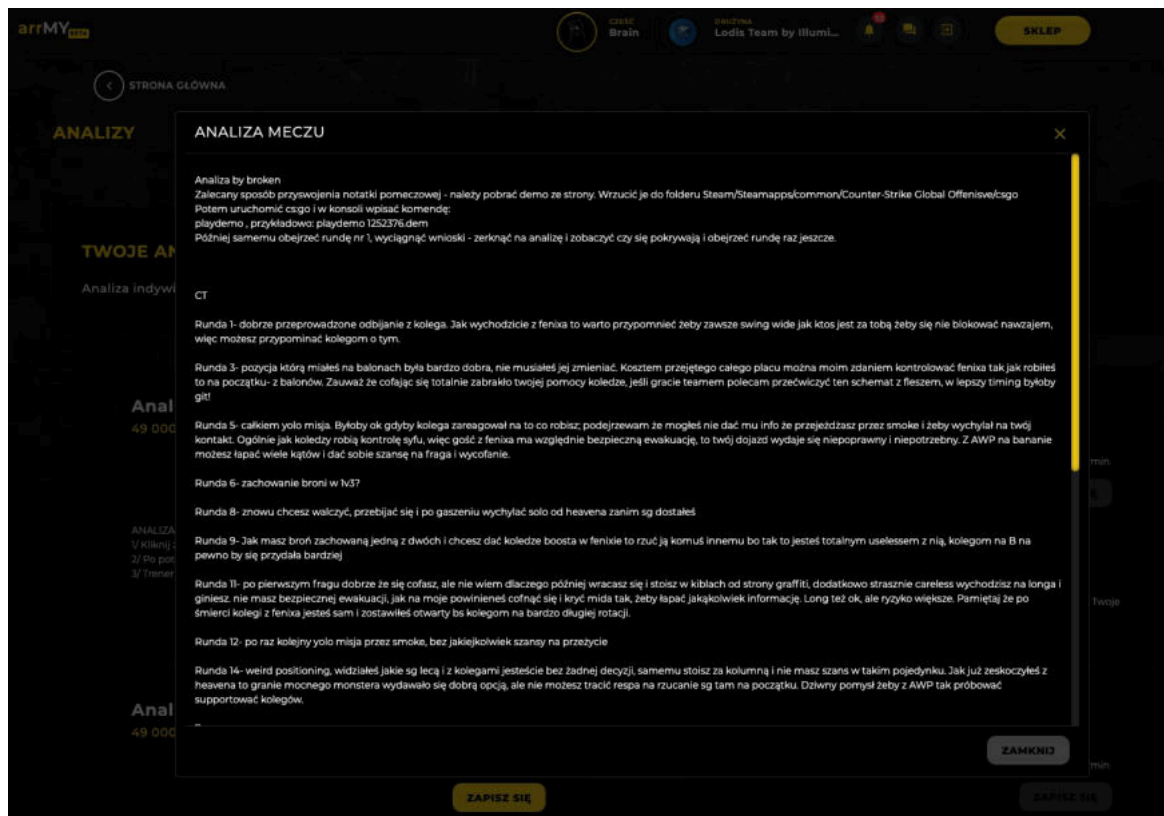
Prezentację zaczniemy od widoków generowanych w kontekście pracy z trenerami, którzy mogą komunikować swoje wytyczne z zawodnikami i drużynami na żywo za pośrednictwem czatu (Rys. 16) lub w formie szeregu analiz (Rys. 10, 11, 12, 13, 14, 15):

- Analiza indywidualna tekstowa
- Analiza drużynowa tekstowa
- Analiza indywidualna live
- Analiza analiza drużynowa live

Rys. 10 Panel analiz – widok zbiorczy z punktu widzenia gracza.



Rys. 11 Panel analiz – widok wykonanej analizy z punktu widzenia gracza.



Rys. 12 Panel analiz tekstowych – widok tabelaryczny z punktu widzenia trenera.

DATA UTWORZENIA	KATEGORIA	UŻYTKOWNIK	ANALITYK	DEMO	ANALIZA
24/05/2021 23:36 pon	Analiza drużynowa tekstowa	Karol Płwnicki KEMi	Wojciech Jaworski Fizer	DEMO	[ikony]
23/05/2021 22:20 ndz	Analiza indywidualna tekstowa	Jakub Świątkowski Świątkowski tsc	Marcin Klusek Klusek	---	[ikony]
22/02/2021 15:33 śr	Analiza indywidualna tekstowa	Stanisław Skrypczak Xyz	Marcin Klusek Klusek	DEMO	[ikony]
14/02/2021 05:43 ndz	Analiza indywidualna tekstowa	Mateusz Kalinowski Treizerro	Wojciech Jaworski Fizer	DEMO	[ikony]
10/02/2021 11:42 śr	Analiza drużynowa tekstowa	Paweł Wiesiołek eVs	Bartłomiej Cawlas BCC	DEMO	[ikony]
08/02/2021 19:56 pon	Analiza indywidualna tekstowa	Milosz Kowalski MIRK	Kuba Kubiak Kubik	DEMO	[ikony]
07/02/2021 21:46 ndz	Analiza drużynowa tekstowa	Michał Orlikowski Bli@y	Bartłomiej Cawlas BCC	---	[ikony]
04/02/2021 19:18 czw	Analiza indywidualna tekstowa	Alex Maciaszek AxiM	Marcin Klusek Klusek	---	[ikony]
04/02/2021 18:20 czw	Analiza indywidualna tekstowa	Robert Górny Semtek	Bartek Szef BartekP	---	[ikony]
04/02/2021 17:18 czw	Analiza indywidualna tekstowa	Bartłomiej Janaszek Dlsta	Marcin Klusek Klusek	DEMO	[ikony]

Rys. 13 Panel analiz tekstowych - widok edycji z punktu widzenia trenera.

ANALIZA ROZEGRANEJ MAPY

Zamawiający heniek

CT
1.RUNDA
Gracie we 4B + 1A, czyli gracze na retake A. Def + SG jest szczególnie ważny na mirku przy retake A więc warto się zastanowić czy nie powinien ktoś kupić.

Co do twojej pozycji na 1:33+- idziesz do okna I z kolegą walczycie z galą, pytanie po co skoro tak naprawdę chcecie, żeby przeciwnik wszedł wam na B I

Zamawiający zostanie powiadomiony mailowo o przygotowanej notatce.

ZATWIERDŹ ANULUJ

Rys. 14 Panel analiz map - widok tabelaryczny z punktu widzenia trenera.

DATA ZGLOSZENIA	ZAWODNIK	ETAP	DATA MECZU	TRENER	MAPA	DEMO	ANALITYK	DATA ZMIANY	SMS
16/02/2021 01:50 wt	Michał Łoś Kiro	Etap III	07/07/2020 18:00 wt	Fizer	MIRAGE	DEMO	Fizer	04/03/2021 21:34 czw	
22/09/2020 12:59 wt	Test Test Test10	Etap turniejowy	21/05/2020 18:00 czw	Fizer	TRAIN	DEMO	Klusek	22/09/2020 13:00 wt	
01/09/2020 10:24 wt	Adrian Woźniak adikwik	Army Teams	14/08/2020 18:00 pt	inwood	MIRAGE	DEMO	inwood	29/09/2020 14:42 wt	
24/08/2020 18:04 pon	Maksymilian Pyc DrVinther	Etap turniejowy	29/07/2020 18:00 śr	inwood	TRAIN	DEMO	inwood	14/09/2020 13:44 pon	
23/08/2020 17:16 ndz	Michał Kowalczyk Majik	Etap IV	03/08/2020 18:00 pon	BGG	TRAIN	DEMO	Szpadlo	15/09/2020 13:04 wt	
16/08/2020 18:24 ndz	Maciej Pobłocki xf0rget	Etap turniejowy	04/08/2020 18:00 wt	BGG	INFERNO	DEMO	Szpadlo	15/09/2020 14:20 wt	
14/08/2020 19:35 pt	Dawid Gościński Blja	Army Teams	13/07/2020 18:00 pon	Fizer	NUKE	DEMO	Klusek	01/10/2020 16:55 czw	
13/08/2020 19:24 czw	Daniel Kościelecki Delor	Army Teams	01/07/2020 18:00 śr	BGG	MIRAGE	DEMO	inwood	14/09/2020 13:44 pon	
07/08/2020 22:47 pt	Roch Pankowski Roche	Etap turniejowy	16/07/2020 18:00 czw	BGG	TRAIN	DEMO	inwood	14/09/2020 13:44 pon	
07/08/2020 22:41 pt	Kacper Marcinkowski giebe	Etap IV	07/08/2020 18:00 pt	Kubik	TRAIN	DEMO	Szpadlo	15/09/2020 15:53 wt	

Rys. 15 Panel analiz map - widok edycji z punktu widzenia trenera.

ANALIZA ROZEGRANEJ MAPY

Zawodnik (DAB), mapa Mirage

#ARRMY
A Proszę nie udostępnić bez zgody

Zalecany sposób przywołania notatki pomocowej - Należy pobrać demo ze strony. Wzrostić je do folderu Steam\Steamapps\common\Counter-Strike Global Offensive\demo
Polem uruchomić ogg i w konsoli wpisać komendę
playdemo "nazwa.dem", przykładowo playdemo 1252376.dem

Później samemu obejrzeć rundę nr 1, wyciągnąć wnioski - zerknąć na analizę i zobaczyć czy się pokrywają i obejrzeć rundę raz jeszcze.

runda 1,
Jeżeli wybiegacie z connectora to stajcie kierować się w stronę ławki, ponieważ wbiegając na schody otwierasz się na masę pozycji z których przeciwnik może Cię zabić.
Gdybyś pobiegł razem z kolegą ławką to byłoby szansa na re-fraga a tak pojedynczo byłicie bez szans.

runda 2,
Taki smok na dojazd jest. Należy wkroczyć na kocz i go rzucić. Jeżeli przeciwnik wychylił się z góry connectora to was widzi, a w tym smoku chodzi o to, żeby odciąć wzrok przeciwnikom.

runda 3,
Kolejny smok niefragowy, tym razem do dema. Ogólnie można znaleźć łatwiejsze sposoby na zrużenie tego smoka. Polecam zerknąć na demka drużyny, tam na pewno trzaskają na kilka różnych sposobów i wybierawcie sobie ten, który Ci odpowiada.

runda 4,
Zawodnik zostanie powiadomiony o przygotowanej notatce.

ZATWIERDZ ANULUJ

Rys. 16 Czat drużynowy – widok z punktu widzenia graczy – umożliwia przesyłanie komunikatów od trenerów do całych drużyn oraz komunikacje między członkami drużyny.

CZAT DRUŻYNOWY

rozgrywek - kwalifikacje do Ligi RISING oraz OPEN (do której może zapisać się KAŻDY!):
<https://bit.ly/armyturnieje> oraz <https://bit.ly/armyligi>. Wyniki drużyny w ramach rozgrywek będą uwzględniane przez ranking Cybersport. Czekamy na Was!

07.05 00:02 **Fizer**: Hej, został wam wylosowany przeciwnik w closed quali do ligi masters
<https://army.pl/poczekalnia/1032> (Tutaj lobby meczowe) Proszę o podanie tam waszej dostępności według instrukcji!

12.05 20:50 **Klusek**: Cześć, macie kolejnego rywala w drabince. Proszę o wypisanie dostępności -
<https://army.pl/poczekalnia/1043>

12.05 22:08 **Klusek**: Ze względów technicznych musiałem utworzyć nową poczekalnię gdzie proszę o napisanie terminów <https://army.pl/poczekalnia/1044>

17.05 15:50 **Klusek**: Cześć, za udział w Closed Quali do Masters S1 macie zagwarantowane miejsce w lidze Rising - jeżeli nie uda się dostać do Masters.

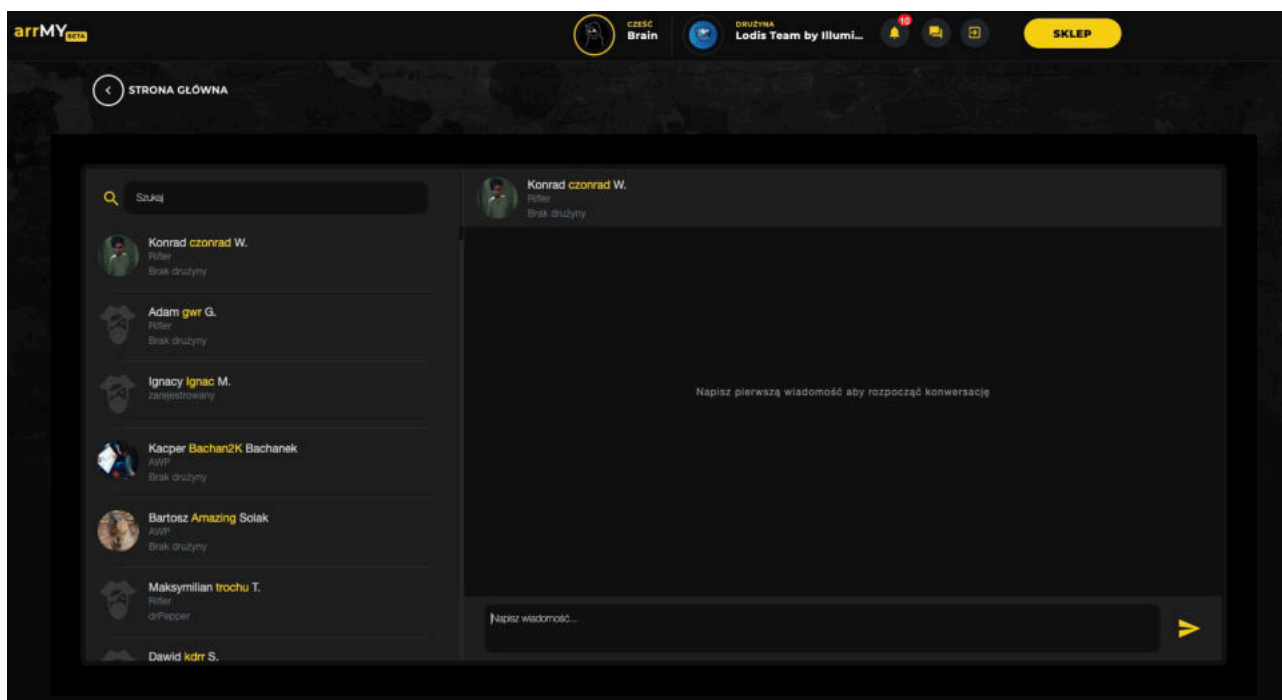
>> Połączono z czatem

>> Wpisz komendę **!admin**, aby poprosić admina i opisz swój problem

Napisz wiadomość...

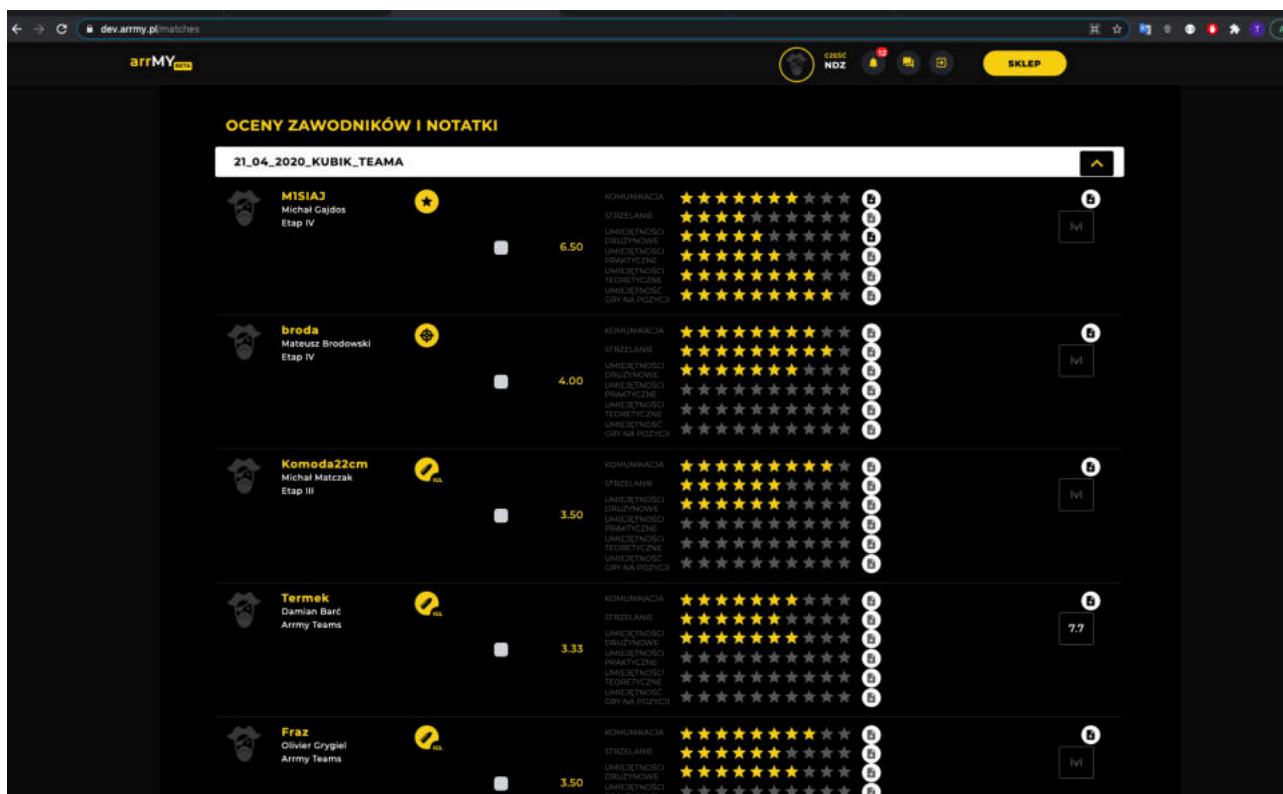


Rys. 17 Czat indywidualny – widok z punktu widzenia każdego typu użytkownika (np. gracz, trener) – umożliwia przesyłanie komunikatów pomiędzy wszystkimi użytkownikami platformy arrMY.

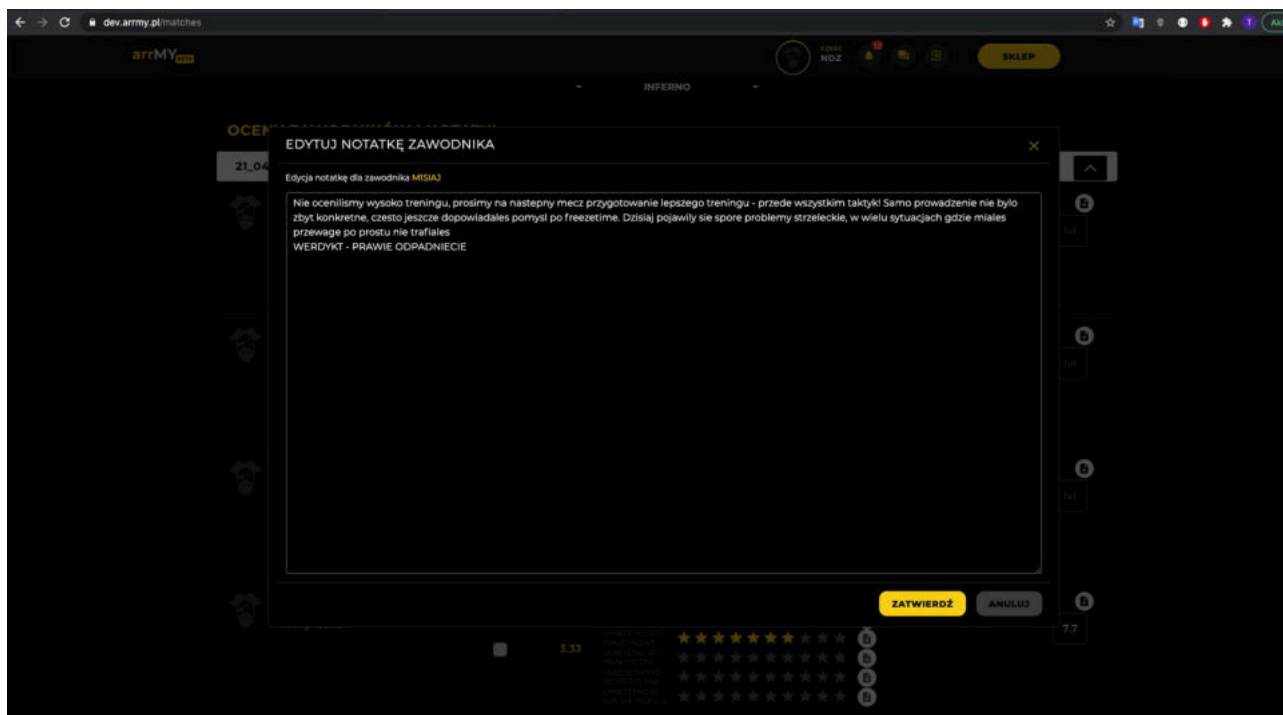


Dodatkowo trenerzy mają możliwość tworzenia ocen i notatek na temat danych zawodników (Rys. 18, 19).

Rys. 18 Panel ocen zawodników – widok z punktu widzenia trenera.



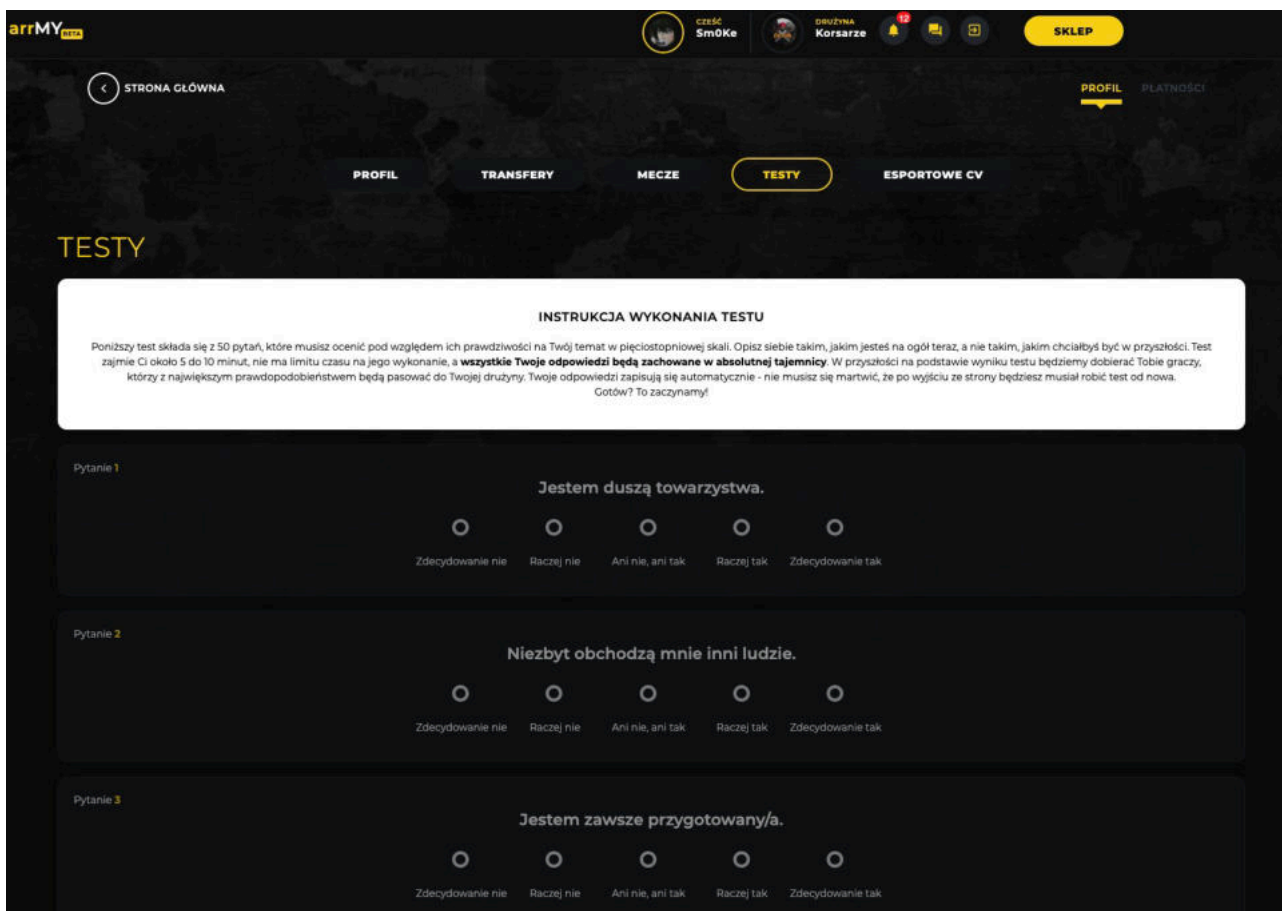
Rys. 19 Panel ocen zawodników – edycja notatki z punktu widzenia trenera.



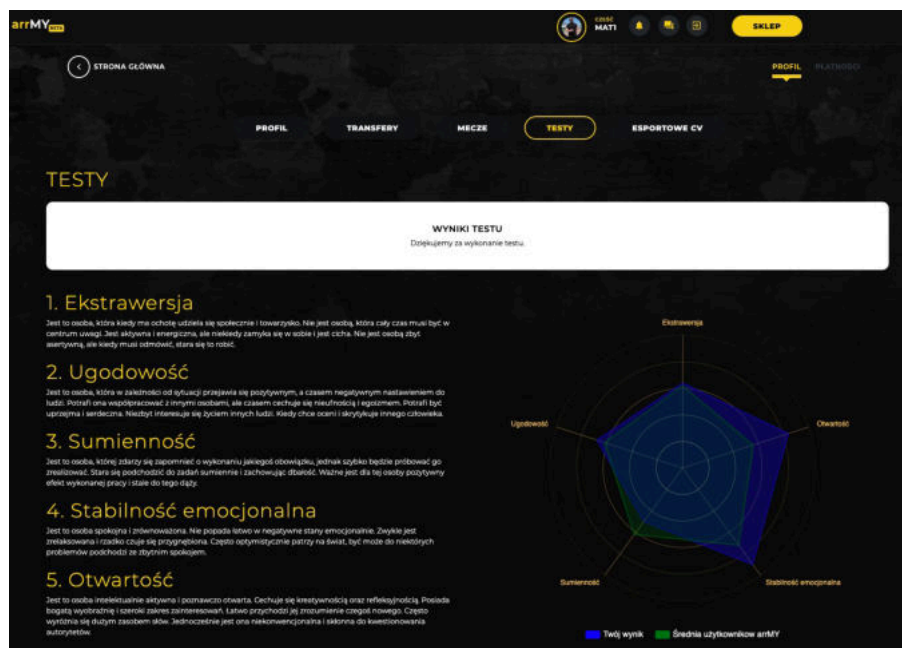
3.2 Narzędzia dla psychologów.

Szczegółowy opis interfejsów w kontekście badań psychologicznych umieściliśmy w raporcie z etapu V punkt 1. Niemniej jednak prace postępowały i to, czego nauczyliśmy się od ekspertów dziedzinowych (psychologów), pozwoliło nam w dużym stopniu jeszcze bardziej zautomatyzować proces przeprowadzenia badania (Rys. 20) oraz prezentacji jego wyników (Rys. 21). Dzięki takiemu podejściu każdy gracz w zaledwie kilka minut jest w stanie dowiedzieć się wiele ciekawych rzeczy na temat swojej osobowości i sprawdzić jak wypada na tle przebadanej populacji graczy projektu arrMY (Rys. 21).

Rys. 20 Panel testy – widok testu badającego osobowość gracza.



Rys. 21 Panel testy – widok wyniku badania osobowości gracza.



Kończąc niniejszy raport należy wspomnieć, że narzędzia takie jak czat (Rys. 16, 17) są również dostępne dla psychologów - co umożliwi ekspertom bezpośredni kontakt z graczem lub całą drużyną.

Data realizacji: 01.03.2021

podpisano: Aleksander Kaim

3.7 System doboru graczy przechodzi beta testy.

Dotychczasowa realizacja kamieni milowych i ciągłe testy w warunkach naturalnych dla wydarzeń esportowych Spółka przeszła do etapu upublicznienia oprogramowania dla podmiotów zewnętrznych. To faza beta testów, które wymagały licznych spotkań z podmiotami zewnętrznymi związanymi esportem i prezentacji dotychczasowych osiągnięć projektu oraz zaproszenie do wykorzystania oprogramowania.

Projekt stworzył przestrzeń w sieci, który jest efektem całorocznej pracy. Panel army.pl został udostępniony nie tylko zawodnikom, ale i obecnym na rynku drużynom esportowym i stał się dla nich zasobem do identyfikowania zawodników i budowania z nich drużyn talentów, które w przyszłości mają stanowić o nowej jakości gry CS:GO na świecie. Aby ułatwić zrozumienie oprogramowania zorganizowane zostały specjalne rozgrywki dla Akademii profesjonalnych drużyn polskiej sceny esportowej. Warto zaznaczyć, że Spółka traktuje Polską scenę tylko jako proof of concept, jeśli zaczniesz monetizować można łatwo skalować zagranicę.

Pośród dostępnych w Polsce drużyn, praktycznie wszystkie wyraziły swoją gotowość do działania w projekcie. Wszystkie uznały nowy sposób weryfikacji zawodników i system uczenia maszynowego przy

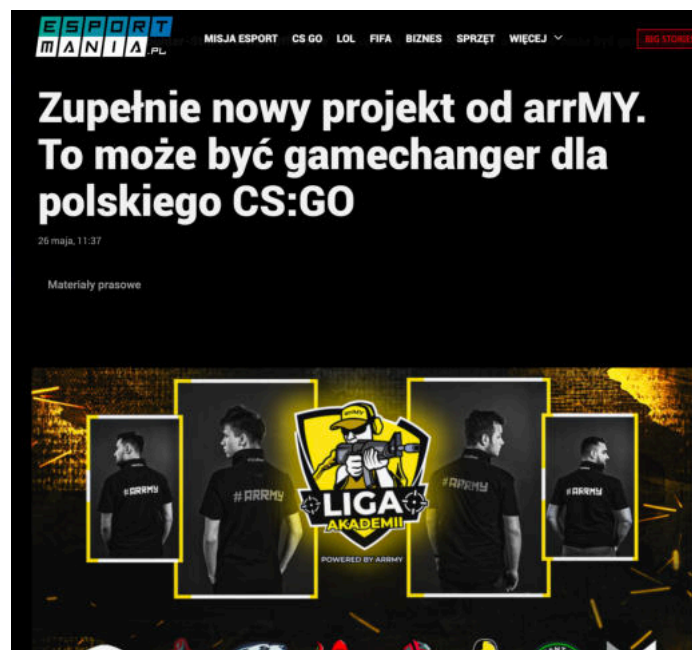


wyborze graczy za świetne rozwiązanie. Przystąpiono zatem do finalizacji umów i uruchomienia pierwszych rozgrywek organizowanych w całości w panelu. Warto zaznaczyć, że panel jest całkowicie samowystarczalny do tworzenia rozgrywek i identyfikacji graczy i drużyn. Na dzień tworzenia raportu swoją obecność udokumentowały umowami drużyny:

- Anonymo Esports
- Cleant Mix
- Avez Esports
- Dr. Pepper Academy
- Honoris
- Lodis
- Zgorzelec Turów
- Pompa Team
- ESCA Gaming

Z pewnością nie są to ostatnie ogłoszenia, bo pozostałe drużyny jak Wisła All in! Games, AGO Esports czy Pact blokują tylko kwestie formalne, a umowy z nimi są procesowane.

Po zakontraktowaniu czołowych polskich organizacji efekty projektu zostały ogłoszone medialnie, co spotkało się ze świetnym przyjęciem w mediach esportowych:




<https://esportmania.pl/counter-strike-global-offensive/zupelnie-nowy-projekt-od-arrmy-to-moze-byc-gamechanger-dla-polskiego-csgo/4n9pwxk>

<https://cybersport.pl/296297/szansa-dla-mlodych-talentow-csgo-arrmy-zapowiada-lige-akademii/>



Obecność czołowych drużyn w rozgrywkach została odebrana przez młodych zawodników jako szansa na dostanie się do wymarzonych teamów, a to zaowocowało dodatkowymi zgłoszeniami i weryfikacjami, które na bieżąco są prowadzone przez osoby zaangażowane w projekt.



Na dzień tworzenia raportu baza graczy projektu zawiera 3109 zawodników i 76 trenerów.

Całe oprogramowanie, które dokumentuje i zbiera całość prac jest panel arrMY.pl dostępny po stworzeniu konta i zalogowaniu. System zawiera wyszukiwarkę użytkowników, która korzystając z algorytmów sztucznej inteligencji podpowiada, którzy użytkownicy mają największe prawdopodobieństwo wygrania meczu. System posiada usługę wprowadzania trenerów i zawodników, a także realizacji testów i ocen umiejętności gry. Posiada historię rozegranych meczy. W zapleczu widzimy także dane, najlepszej korelacji z zakładanym wynikiem.

Tak rozbudowana baza pozwala w przyszłości zarabiać na dostępie do bazy zawodników oraz udzielaniu licencji na dostęp do zawodników, predykcji i weryfikacji. Już dzisiaj zawodnicy wyrażają gotowość do zakupu usług płatnych. Organizacje esportowe zgłaszają gotowość do zakupu abonamentów i licencji na wykorzystywanie systemu. Pojawiają się także nowe podmioty komercyjne chcące w panelu organizować wydarzenia esportowe.



Powyższe jest założeniem ostatniego kamienia milowego, który wskazuje na kompletne wykonanie projektu. Pełna baza całościowo zebranej wiedzy dostępna jest w serwisie army.pl gotowa do wglądu zainteresowanych użytkowników.

Spółka prowadzi zaawansowane rozmowy z inwestorami oraz podmiotami zainteresowanymi korzystaniem z dalszych usług czy to w postaci kontynuowania weryfikacji czy jego komercyjnym wykorzystaniem. Dzięki niezależności od podmiotów zewnętrznych zgromadzona baza graczy pozwala zarówno na dalsze badania jak i komercyjne wykorzystanie na zasadzie licencji zewnętrznych. Pojawiają się także firmy zainteresowane skorzystaniem z infrastruktury serwerowej oraz bazą trenerów i systemem AI. Z pewnością technologia będzie nadal rozwijana. Na dzień tworzenia raportu najbardziej prawdopodobne wydaje się udostępnianie całej infrastruktury na zasadzie licencji.

Data pełnej realizacji projektu: 01.04.2021

podpisano: Aleksander Kaim

Data realizacji raportu i opracowań: 30.04.2021

podpisano: Aleksander Kaim

Pełne zasoby zdobytych materiałów dostępne do wglądu w serwisie army.pl

