

Nitelikler Uzayı

Foundations • The Valuation Engineer

Bert Craytor • 7 Ağustos 2026

Sürüm 1.0.0

DOI: [10.67330/3yymh010](https://doi.org/10.67330/3yymh010)

Türkçe sürüm — yapay zekâ desteğiyle hazırlanmış ve editoryal denetimden geçirilmiştir; İngilizce sürüm esas alınır.

Biçimsel tanım. Bir heterojen mallar sınıfının nitelikler uzayı, koordinatları alıcıların değerlediği nitelikleri indeksleyen ve her malın kendi nitelik düzeyleri vektörüyle temsil edildiği vektör uzayıdır.

Sezgisel çerçeve. Önceki madde, heterojen bir malın belirgin bir nitelik demeti olduğunu ortaya koydu. Doğal olarak sıradaki soru şudur: böyle demetleri biçimsel olarak nasıl betimlemeli ve karşılaştırmalıyız? Lancaster’a (1966) ait yanıt, her malı, eksenleri alıcıların önemseydiği nitelikler olan bir vektör uzayında nokta olarak ele almaktır.

Bu temsilde bir Pacifica konutu artık “Park Pacifica’da bir ev” değildir; brüt yaşam alanı, arsa büyüklüğü, manzara, durum, okul bölgesi, okyanusa uzaklık vb. için koordinatları olan bir vektördür. Bu nitelik değerlerinin tümünü paylaşan iki taşınmaz nitelikler uzayında aynı noktayı işgal ederdi; herhangi bir nitelikte farklılaşan taşınmazlar farklı noktaları işgal eder. Uzayın geometrisi, iki taşınmazın ne kadar yakın ya da ne kadar farklı olduğunu, alıcıların ayırdığı tüm boyutları kapsayacak biçimde kodlar.

Uzayın boyutu, incelenen piyasa için hangi niteliklerin ilgili olduğuna bağlıdır. Tipik bir konut değerlemesinde ilgili uzay bir düzine boyuta sahip olabilir: fiziksel (GLA, arsa, yatak odası, banyo, yaş, kalite, durum), konumsal (okul bölgesi, manzara, olanaklara ya da olumsuzluklara yakınlık) ve hukuki/iktisadi (imar, irtifaklar). Ticari bir değerlemede ilgili boyutlar nakit akışı niteliklerine (kira yapısı, kiracı kalitesi, doluluk) kayar, ama altta yatan geometrik fikir aynıdır.

Nitelikler uzayını yararlı kılan şey, niteliksel bir uygulamacı sezgisini (“bu emsaller konu taşınmaza benziyor”) niceliksel bir iddiaya (“bu emsaller nitelikler uzayında konu taşınmaza yakın”) dönüştürmesidir. Uzaklık bir kez tanımlandığında, her satış karşılaştırma kararı uzaydaki konuma ilişkin bir önerme olarak incelenebilir.

Değerleme uzmanları kavramla nerede karşılaşır. Değerleme uzmanları sürekli olarak nitelikler uzayında çalışır, genellikle ona bir ad vermeden. Satış karşılaştırma tablosunun her satırı bir koordinat eksenidir; her emsal koordinat değerlerinden oluşan bir satır vektörüdür; her düzeltme, diğerlerini sabit tutarken bir eksen boyunca hareket etme girişimidir.

Bu sayı boyunca kullanacağımız sekiz Pacifica emsali bu kuruluşu doğrudan örnekler. Her emsal, GLA, arsa büyüklüğü, manzara ve durumun gerdiği dört boyutlu bir nitelikler uzayında bir noktadır:

Emsal	GLA (sf)	Arsa (sf)	Manzara	Durum	Satış fiyatı
A	1,650	9,000	var	iyi	\$1,425,000
B	1,650	7,200	yok	iyi	\$1,280,000
C	1,850	7,500	yok	iyi	\$1,407,500
D	1,450	7,000	yok	iyi	\$1,155,000
E	1,700	8,000	var	mükemmel	\$1,470,000
F	1,550	7,100	yok	orta	\$1,177,500
G	1,700	10,500	yok	iyi	\$1,392,500
H	1,600	7,300	yok	iyi	\$1,312,500

Önceki maddedeki A ve B emsalleri ilk iki satırdır; kalan altısı örneği, sayının geri kalanında yararlanacağımız biçimlerde genişletir.

Her emsal $\mathbb{R}^4$ içinde bir noktadır:

- A emsali (1650, 9000, 1, 2) konumundadır.
- B emsali (1650, 7200, 0, 2) konumundadır.
- G emsali (1700, 10500, 0, 2) konumundadır.

Manzara ve durum koordinatları sayısal olarak kodlanmıştır (manzara $\{0, 1\}$, durum $\{1, 2, 3\}$ olarak); fiyat ise nitelikler uzayının bir koordinatı *değildir*, uzaydaki konumun bir fonksiyonudur.

Savunulabilirlik açısından neden önemlidir. Nitelikler uzayı çerçevesi, emsal seçiminin gerçekte ne olduğunu keskinleştirir. Bir emsal yalnızca “benzer bir taşınmaz” değildir; nitelikler uzayının ilgili bölgesinde konu taşınmaza yakın bir noktadır. Bir emsal uzayda konu taşınmaza ne kadar yakınsa, gereken düzeltmeler o kadar küçülür ve işaret edilen değer o kadar güvenilir olur.

Bu yeniden çerçeveleme, gayriresmî tablonun gizlediği birkaç uygulama sorusunu açığa çıkarır:

- *Hangi boyutlar önemlidir?* Eksenlerin seçimi bir modelleme kararıdır. “Manzara”yı bir eksen olarak dahil etmek, ancak piyasa manzarayı ayrıca fiyatlıyorsa anlamlıdır; “Feng Shui yönelimi”ni dahil etmek, ancak bir piyasa kesiti onu fiyatlıyorsa anlamlıdır. Savunulabilir değerlendirme, yalnızca eksenler üzerindeki değerleri değil, eksenlerin kendisini de savunmayı gerektirir.
- *Hangi uzaklık ölçütü geçerlidir?* İki emsal, nitelikler uzayında birbirinden uzak oldukları için fiyatta \$200,000 farklılaşabilir, ama uzaklık hesabı her eksen için bir ölçekleme gerektirir. Dönüştürülmemiş Öklit uzaklığı, bir fit kare GLA’yı bir fit kare arsaya eşdeğer sayar; piyasa ise saymaz.
- *Emsaller, fiyat fonksiyonunun iyi davrandığı bir bölgede midir?* Konu taşınmaz, nitelikler uzayının seyrek örneklenmiş bir köşesinde duruyorsa hiçbir emsal ona yakın değildir ve değer işareti zorunlu olarak dışdeğerlemeye dayanır.

Çözümlü değerlendirme örneği. Sekiz Pacifica emsali, dört boyutlu nitelikler uzayının görece derli toplu bir bölgesini işgal eder. (1,700, 7,500, 1, 2) konumundaki varsayımsal bir konu taşınmaza — 1,700 sf, 7,500 sf arsa, manzaralı, iyi durumda — hangi emsalin “en yakın” olduğu sorusunu ele alalım.

Ölçeklenmemiş eksenlerle naif biçimde Öklit uzaklığı kullanırsak, arsa boyutu baskın çıkar; çünkü değerleri (7,000–10,500) manzara (0–1) ya da durumdan (1–3) sayısal olarak çok daha büyüktür. Konu taşınmaza uzaklıklar:

Emsal	Uzaklık (ölçeklenmemiş Öklit)	Notlar
A	1,501	manzara uyuyor; arsa baskın
B	308	manzara farklı; arsa yakın
C	230	manzara farklı; arsa yakın
D	559	manzara farklı; GLA sapıyor
E	502	manzara uyuyor; durum farklı
F	422	manzara ve durum farklı
G	3,000	manzara farklı; arsa çok uzak
H	224	manzara farklı; hepsinin en yakını

Ham uzaklığa göre en yakın komşu H emsalidir. Ne var ki H emsalinin manzarası yoktur, konu taşınmazın ise vardır. Naif ölçüt bizi yanıltmıştır: arsa boyutunun sayısal ölçeği, fiyat açısından gerçekte daha önemli olan kategorik manzara boyutunu bastırmıştır.

Savunulabilir bir uzaklık ölçütü her eksen kendi örtük fiyatıyla — kabaca, o eksenindeki bir birimlik değişimin kaç dolar ettiğiyle — ölçeklerdi. Eksenler örtük fiyata göre ölçeklendiğinde manzara (~\$100,000 değerinde) artık arsa tarafından (fit kare başına ~\$25) bastırılmaz. O zaman konu taşınmazla manzarada uyuşan A emsali, uygun birincil emsal olarak öne çıkar.

İzleyen maddelerde geliştirilen örtük fiyat aygıtının sağladığı tam da budur: nitelikler uzayının ilkeli bir ölçeklenmesi, yani “yakınlığın” geometrik bir tahminden piyasadan türetilmiş bir hesaba dönüşmesi.

Kaynakça.

Lancaster, K. J. (1966). A New Approach to Consumer Theory. *Journal of Political Economy*, 74(2), 132–157.
 Rosen, S. (1974). Hedonic Prices and Implicit Markets: Product Differentiation in Pure Competition. *Journal of Political Economy*, 82(1), 34–55.

Çapraz başvurular: heterojen mal; hedonik fiyat fonksiyonu; örtük fiyat.

Ek: Prolog biçimselleştirmesi

Aşağıdaki makine tarafından okunabilir yardımcı dosya (002-characteristics-space.pl) bu maddeyi derginin Prolog bilgi tabanında biçimselleştirir. Ayrıca bu makalenin yanında göz atılabilir bir dizgi nüshası (galley) olarak yayımlanır.

```
%% 002-characteristics-space.pl
%%
%% Prolog companion to Foundations Vol. 1, Issue 1, Article 002
%% Title: Characteristics Space
%% Author: Bert Craytor
%% Concept: characteristics_space
%% Version: 0.1.0-draft

% =====
% DICTIONARY IMPORT
% =====

:- use_module('.././.././././tools/dictionary/dictionary').
:- dictionary_release('dictionary-2026.1').

% --- From the dictionary (loaded via :- use_module above) -----
```

```

% term(characteristics_space, "Characteristics Space", economic_theory,
%      "The characteristics space of a class of heterogeneous goods is
%      the vector space whose coordinates index the attributes that
%      buyers value, and in which each good is represented by the
%      vector of its attribute levels.", published, 'dictionary-2026.1').
%
% term(heterogeneous_good, ...).
% term(hedonic_price_function, ...).
% term(implicit_price, ...).
%
% generalized_by(characteristics_space, lancaster_1966).
% depends_on(characteristics_space, heterogeneous_good).
% -----

:- use_terms([ characteristics_space, heterogeneous_good,
                hedonic_price_function, implicit_price,
                comp_selection, sales_comparison_approach,
                real_estate ]).
:- use_relations([related/2, depends_on/2, generalized_by/2]).

% =====
% ARTICLE SUBJECT
% =====

article_concept(characteristics_space).
article_issue(volume(1), number(1), year(2026)).
article_id('foundations.2026.002').

% =====
% LOCAL VOCABULARY
% =====
%
% Narrow article-local field names + the dimensions of the worked
% example's characteristics space.

local_term(dimension).
local_term(coordinate).
local_term(euclidean_distance).
local_term(distance_metric).
local_term(nearest_neighbor).

% =====
% FORMAL ATTRIBUTION
% =====

% The construction is due to Lancaster (1966), as noted in citations.
attributed_construction(characteristics_space, lancaster_1966).

% =====
% THE ARTICLE'S CLAIM ABOUT REPRESENTATION
% =====
%
% A heterogeneous good becomes a point in a vector space. Each axis is
% a characteristic buyers value; each good is the vector of its
% attribute levels.

representation_of(heterogeneous_good, point_in_vector_space).

% Examples of dimensions relevant to residential appraisal.

```

```

residential_dimension(gla_sqft).
residential_dimension(lot_sqft).
residential_dimension(view).
residential_dimension(cond).
residential_dimension(bedrooms).
residential_dimension(baths).
residential_dimension(age).
residential_dimension(quality).
residential_dimension(school_district).
residential_dimension(distance_to_amenity).
residential_dimension(zoning).

% Examples of dimensions relevant to commercial appraisal - included
% to make the article's point that the dimensions shift with market.
commercial_dimension(lease_structure).
commercial_dimension(tenant_quality).
commercial_dimension(occupancy).
commercial_dimension(cash_flow_profile).

% =====
% APPRAISER ENCOUNTERS
% =====
%
% Mapping appraisal practice onto the characteristics-space framework.

practice_to_space_correspondence(
    sales_comparison_grid_line, coordinate_axis,
    "A grid line is an axis.").
practice_to_space_correspondence(
    comp_row, row_vector,
    "A comp is a vector of coordinate values.").
practice_to_space_correspondence(
    adjustment, movement_along_axis,
    "An adjustment moves along one axis holding others fixed.").

% =====
% WORKED EXAMPLE
% =====
%
% The 8 Pacifica comps are points in a 4D characteristics space spanned
% by GLA, lot_sqft, view, cond_numeric. Bring in the shared dataset.

:- consult('../..kb/pacifica_comps').

% Axes of the chosen space for this article's analysis.
axis(gla_sqft).
axis(lot_sqft).
axis(view).
axis(cond_numeric).

% Numeric encoding for non-numeric axes.
encode(view, no, 0).
encode(view, yes, 1).
encode(cond_numeric, 1, 1).
encode(cond_numeric, 2, 2).
encode(cond_numeric, 3, 3).

%! coord(?Property, ?Axis, ?Numeric) is nondet.
%
```

```

% Numeric coordinate of Property along Axis. Handles symbolic attribute
% values by encoding them.

coord(P, A, N) :-
    attribute_value(P, A, V),
    ( number(V) -> N = V ; encode(A, V, N) ).

%! point(?Property, -Vector) is det.
%
% Vector representation of Property in the 4D characteristics space.

point(P, [GLA, Lot, View, Cond]) :-
    coord(P, gla_sqft, GLA),
    coord(P, lot_sqft, Lot),
    coord(P, view, View),
    coord(P, cond_numeric, Cond).

% =====
% THE HYPOTHETICAL SUBJECT
% =====
%
% The article tests distance metrics against this hypothetical property.

hypothetical_subject(subject).
attribute_value(subject, gla_sqft, 1700).
attribute_value(subject, lot_sqft, 7500).
attribute_value(subject, view, yes).
attribute_value(subject, cond_numeric, 2).

% =====
% NAIVE EUCLIDEAN DISTANCE (the article's straw distance metric)
% =====
%
% Computes the unscaled Euclidean distance between Property and the
% hypothetical subject. Used to demonstrate that unscaled distances
% mislead: the lot dimension dominates because its numeric range is
% much larger than view (0..1) or cond (1..3).

naive_distance_to_subject(P, D) :-
    point(P, V_P),
    point(subject, V_S),
    sum_of_squares(V_P, V_S, S),
    D is sqrt(S).

sum_of_squares([], [], 0).
sum_of_squares([X|Xs], [Y|Ys], S) :-
    sum_of_squares(Xs, Ys, S0),
    D is X - Y,
    S is S0 + D * D.

% =====
% THE ARTICLE'S CENTRAL OBSERVATION
% =====
%
% Under naive Euclidean distance, Comp H is the nearest neighbor. But
% Comp H has no view and the subject does; view matters more to price
% than the naive metric admits. The fix (developed in entries 003-005)
% is to scale each axis by its implicit price.

```

```

claim(naive_metric_misleads,
    "Unscaled Euclidean distance crowds out small-range axes (like view) under large-range axes (
    ↪ like lot_sqft). A market-defensible distance scales each axis by its implicit price.>").

% =====
% DEFENSIBILITY QUESTIONS RAISED
% =====
%
% Three questions the characteristics-space framing makes explicit.

defensibility_question(which_dimensions,
    "The choice of axes is a modeling decision. Defending an appraisal requires defending the axes,
    ↪ not just the values on them.>").
defensibility_question(distance_metric,
    "Untransformed Euclidean distance treats one sqft of GLA as equivalent to one sqft of lot,
    ↪ which the market does not. Distance requires a scaling per axis.>").
defensibility_question(extrapolation_region,
    "If the subject sits in a sparsely-sampled corner of the space, no comp is truly close and the
    ↪ indication is extrapolative.>").

% =====
% INFERENCE RULES
% =====

%! same_point(?A, ?B) is nondet.
%
% Two properties occupy the same point in the characteristics space.
% (Doesn't occur in the running example, but the article notes that it
% would if all coordinates matched.)

same_point(A, B) :-
    point(A, V),
    point(B, V),
    A \== B.

%! nearest_neighbor_by_naive_distance(-P) is semidet.
%
% The comp closest to the subject under the naive Euclidean metric.
% Used to illustrate the article's point that the naive metric chooses
% Comp H, not Comp A.

nearest_neighbor_by_naive_distance(P) :-
    findall(D-Q,
        ( property(Q), Q \== subject, naive_distance_to_subject(Q, D) ),
        Pairs),
    keysort(Pairs, [_P|_]).

% =====
% CROSS-REFERENCES
% =====

cross_reference(heterogeneous_good).
cross_reference(hedonic_price_function).
cross_reference(implicit_price).

```